

# クラウド環境を利用した 洋ナシ果実の外観汚損検出サービスの開発

中澤 健介<sup>1,a)</sup> 山崎 達也<sup>2,b)</sup>

**概要：**新潟県の名産品である洋ナシ「ル レクチエ」(以下、洋ナシ)は、外観品質に基づく出荷規格が等級として新潟県により定められている。現在、洋ナシの等級は農家の目視によって行われており、等級判定の個人差や作業負担が課題となっている。本研究の目的は、これらの課題を解決するために画像処理による等級判定システムの開発し、農家の作業負担を軽減することにある。これまで、洋ナシの外観を撮影した画像から統計的テクスチャ特徴量を用いて汚損を検出する手法と、畳込みニューラルネットワークを用いた外観汚損の分類を行う手法を連続的に実行し、画像入力から汚損分類結果までをエンドツーエンドで実施するシステムを構築してきた。本提案では、汚損分類結果から洋ナシの外観汚損検査を行うサービスを開発し、クラウド環境で実装することにより、スペースの限られている農家の作業場で簡易に行える外観汚損検査サービスを実現した。

**キーワード：**深層学習, 画像処理, クラウド, 洋ナシ等級判定

## 1. はじめに

新潟県名産の高級洋ナシ「ル レクチエ」(以下、洋ナシ)は、新潟県の推進する「にいがたフード・ブランド」の一つとしてブランドを確立している。特にその美しい外観からお歳暮や贈答品としての需要が高く、外観品質は商品の価値に大きな影響を与える。これらの理由から外観品質に基づいた果実の等級が、外観を損なう傷や病害(以下、外観汚損)の種類や程度により表 1 に示すような出荷規格として新潟県により定められている。

洋ナシ生産者は出荷時に外観汚損の程度に応じた等級判定作業を行っている。しかしながら、洋ナシの等級は定量的な判定が困難であり、外観汚損の要因や汚損度合いを総合的に判断し、等級判定を行っているため、熟練の生産者でないと高精度な評価は困難である。このことにより、生産者間での判定基準に個人差があることや判定作業の負担が課題となっている。

本研究では洋ナシを対象とし、生産者の目視により行われている等級判定作業の負担軽減、及び判定基準を統一化

表 1 洋ナシの出荷規格の一例 [1]

Table 1 An example of pear shipping standards

外観汚損名	赤秀	青秀	良
黒斑病	軽く目立たない塊 1 個まで	薄く散らばっているもの (果面の 1/3 以内で目立たない塊 3 個まで)	青秀より劣るもののうち 商品性を有するもの
外傷痕	コルクが薄く目立たないもの (果面の 10 %以内)	コルクが薄く目立たないもの (果面の 1/3 以内)	青秀より劣るもののうち 商品性を有するもの
面状汚損 葉斑	シミだけの薄いもの (果面の 10 %以内)	薄く散らばって色の薄いもの (果面の 1/3 以内)	青秀より劣るもののうち 商品性を有するもの

することに資する外観品質評価システムの構築を目的としている。提案する外観評価システムは、個人で経営している洋ナシ生産者が出荷前に等級判定を行う場面で用いることを想定している。そのため、生産者自身のスペースが限られた作業場で、簡易な操作で利用できる必要がある。そこで本論文では、タブレット端末やスマートフォンのような携帯端末で洋ナシを撮影し、撮影された洋ナシの画像をクラウドシステムの外観汚損検出モデルで外観汚損の検査を行うサービスを提案する。

以降、2 節で関連研究について述べる。3 節で学習に使用するデータセットについて述べ、4 節でサービスの主要な部分である汚損検査のモデルについて述べる。5 節で提案手法を実装したサービスについて述べた後、6 節で本論文のまとめを行う。

## 2. 関連研究

本論文では、洋ナシの外観検査モデルとして、テクスチャ特徴量を用いた外観汚損部の検出と、畳み込みニューラル

<sup>1</sup> 新潟大学大学院自然科学研究科  
Graduate School of Science and Technology, Niigata University

<sup>2</sup> 新潟大学工学部工学科  
Faculty of Engineering Niigata University

a) f21c039a@mail.cc.niigata-u.ac.jp

b) yamazaki.tatsuya@ie.niigata-u.ac.jp

ネットワーク (CNN: Convolutional Neural Network) を用いて検出された外観汚損の分類を行う手法を提案する。本節では、提案手法に対しての関連研究について述べる。

## 2.1 統計的テクスチャ解析

テクスチャとは画像の重要な特徴であり、表面の視覚的な色や明るさの均質さ、触覚的な強弱を感じる凹凸といった部分的変化を全体的に捉えたものである。統計的テクスチャ解析とは、画像を2次元平面とみなし、どのような統計的パラメータで平面上の輝度が構成されているかを解析する手法である。統計的テクスチャ解析は医療分野や土木分野で用いられており [2-4]、農業分野でも異常検知を目的に用いられている [5, 6]。統計的テクスチャ解析としては、同時生成行列 (GLCM: Gray-Level Co-occurrence Matrix) や空間濃度レベル依存法 (SGLDM: Spatial Gray-Level Dependence method)、濃度レベル差分法 (GLDM: Gray-Level Difference Method)、濃度レベルランレングス法 (GLRLML: Gray-Level Run Length Method) などがある。その中でも同時生成行列は他の統計的手法より頑強な手法とされている [7]。

同時生成行列とは Haralick ら [8] により提案された統計的テクスチャ解析の手法の一つである。同時生成行列は、2次元結合確率密度関数に基づくものである。画像の濃度  $i$  の点から一定の変位  $\delta=(r, \theta)$  だけ離れた点で濃度が  $j$  である確率  $P_{\delta}(i, j)(i, j = 0, 1, \dots, n - 1)$  を要素とする正方行列を計算する。画像のある濃度  $i$  の点から一定の変位  $\delta=(r, \theta)$  だけ離れた点の濃度  $j$  が何度出現しているかをカウントした正方行列  $A$  を算出し、その行列の要素の総和が 1.0 になるように正規化した正方行列が、式 (1) で表される同時生成行列  $GLCM$  となる。 $r = 1, \theta = 90^{\circ}$  とした時の変位  $\delta = (r, \theta)$  における同時生成行列の算出方法を図 1 に示す。なお、図 1(c) では少数第 3 位までの表示とし、それ以降の桁は四捨五入している。図 1(a) のような  $3 \times 3$  画素で、画素値が 0 から 3 の画像において、同時生成行列は 4 次正方行列となる。すなわち、同時生成行列は計算する対象画像の画素値の幅を 0 から  $n$  とすると  $(n+1)$  次正方行列となる。

$$GLCM = P_{\delta}(i, j) = \frac{A}{\sum_{(i, j)} A_{(i, j)}} \quad (1)$$

Kim ら [9] はグレープフルーツを対象とし、正常な果実と五つの病害の 6 クラスの分類を行うために HSI 色空間を用いてテクスチャ特徴量を用いて分類を行い、96%の精度で分類できることを示した。Indrian ら [10] はトマトの成熟度を分類するために、GLCM を用いて特徴を抽出し、 $k$ -近傍法を用いて 3 クラス分類を行い正解率 100%という高い精度での分類に成功している。

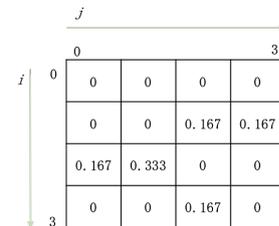
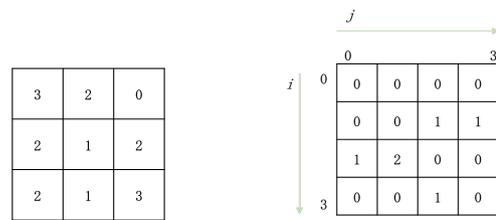


図 1 同時生成行列の計算例 ( $r = (1), \theta = (90^{\circ})$ )

Fig. 1 Example of GLCM calculation ( $r = (1), \theta = (90^{\circ})$ )

## 2.2 深層学習

近年の深層学習を用いた画像認識技術の発展により、農業分野においても深層学習を用いた手法の研究が盛んに行われている [11-13]。特に農業分野の中でも、人の目視による検査を代替するための手法として、畳み込みニューラルネットワーク (CNN: Convolutional Neural Network) を用いた手法が提案されている。Nakano ら [14] はりんごの果実画像から表面の色から 5 種類のクラスに分類するニューラルネットワークモデルを構築し、70%の分類精度で分類できることを示した。川崎ら [15] はきゅうりの葉を対象とし、健全株とウイルス病 2 種の 3 クラス分類を行う実験を行い、92.5%の精度で分類できることを示した。Arthur ら [16] はトマトの利用用途を分類するために、トマト単体で出荷できる状態の healthy とケチャップ工場等で利用する defective の分類を ResNet [17] を用いて行い、94.6%の精度での分類に成功した。Zohou ら [18] は青梅を対象に腐敗、斑点、傷、割れ、正常の 5 クラスの分類を ResNet を用いて行い、平均正解率 93.8%の精度で分類できることを示した。Saumya ら [19] は桃の葉を対象に細菌に侵されているかどうかを分類するモデルを構築し、98.8%の正解率で分類できることを示した。

## 3. 洋ナシのデータ

本研究で使用する画像は、2020 年の 12 月に新潟県三条市にて撮影された洋ナシを用いる。撮影された画像は回転する台座の上に乗せられた洋ナシを横方向から撮影されたものである。撮影時には  $90^{\circ}$  ごとに回転させ、1 果実に対し 4 枚の画像を撮影した。撮影された画像はいずれも  $1536 \times 2048$  ピクセルの 32bit カラー画像である。撮影対象は 299 果実であり、計 1196 枚の画像を撮影した。撮影した洋

ナシ画像の例を図 2 に示す。



図 2 洋ナシの画像例  
Fig. 2 Examples of pear image

#### 4. 提案手法

2 節の関連研究では、果実画像からの汚損や病害を画像単位で高精度で分類する手法を述べた。しかしながら、本研究が対象としている洋ナシでは表 1 に例を示したように、外観汚損の程度や種類によって総合的に等級を判定するため、果実の画像から複数の外観汚損を検出し、分類することと表面果皮から外観汚損の割合を判定する必要がある。

そこで提案手法では、洋ナシ果実画像から外観汚損部の検出と検出された汚損の分類を別々に行うことにより、表面果皮と外観汚損の面積割合を算出し、洋ナシの等級判定を可能にする手法を提案する。

提案手法は、図 3 に示すように輪郭検出部と汚損検出部、汚損分類部の三つのセクションに分かれている。本節では、これら三つのセクションそれぞれについて述べる。なお、以下で実装する手法は全て Python(version 3.8) で記述し、使用するライブラリは以下の通りである。

- scikit-learn (version 0.24.2)
- NumPy (version 1.18.5)
- OpenCV (version 4.5.2)
- scikit-image (version 0.18.1)
- Tensorflow (version 2.4.1)

また、計算環境として、NVIDIA 製の GPU GeForce GTX1080 Ti と AMD 製の CPU Ryzen Threadripper1950X を搭載した Ubuntu(version 20.04.2 LTS) の計算機サーバーを用いた。

##### 4.1 洋ナシの輪郭抽出

洋ナシの輪郭抽出の手順を図 4 に示す。輪郭抽出では、カーネルサイズ 19 でガウシアンフィルタをかけた後、RGB 色空間を HLS 色空間に変換し、彩度を用いて大津の 2 値化 [20] を行う。2 値化を行った画像に対して鈴木ら [21] が提案しているトポロジー解析のアルゴリズムを使用して、2 値化画像の中から輪郭を抽出する。抽出した輪郭の中で最も大きい輪郭を洋ナシの輪郭として抽出する。

##### 4.2 外観汚損の検出

外観汚損の検出に用いる手法は中澤ら [22] が提案してい

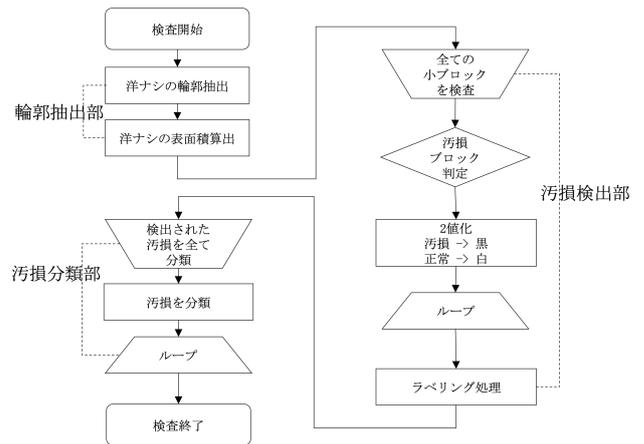


図 3 提案手法の概要  
Fig. 3 Overview of the proposed method

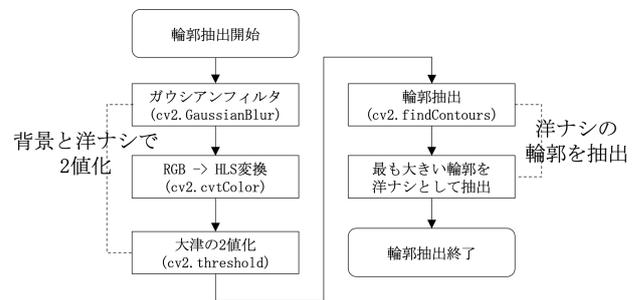


図 4 洋ナシの輪郭抽出  
Fig. 4 Pear contour extraction

る、テクスチャ特徴量をとランダムフォレストを用いた検出手法を用いる。中澤ら [22] の提案手法では、図 5 に示す洋ナシの小ブロック画像を果点なしブロック、果点ありブロック、汚損ブロックの 3 クラスに分類し、テクスチャ特徴量とランダムフォレストを用いて分類する実験を行い、正解率 94.38% の精度で分類できることが示されている。ここでは、果点なしブロックと果点ありブロックを正常ブロック、汚損ブロックを汚損ブロックとする。図 3

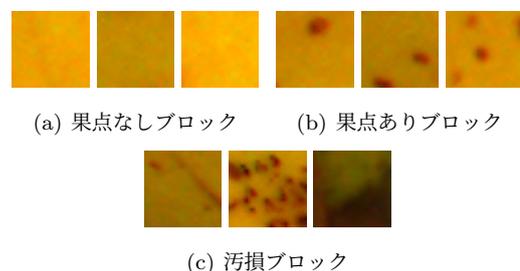
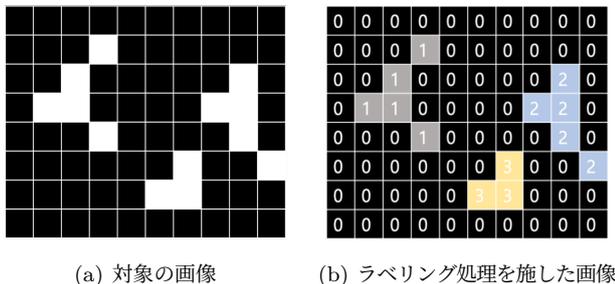


図 5 ブロック画像の例  
Fig. 5 Examples of block images

で示した汚損検出部の汚損ブロック判定に上述の手法を用いて判定を行い、正常ブロックと汚損ブロックで 2 値化を行う。2 値化された画像に対してラベリング処理を施すことにより、果実画像より外観汚損を検出する。ラベリング

処理は、2 値化された画像に対して、連続した画素に同じ番号を振る処理である。ラベリング処理の例を図 6 に示す。本提案手法では、縦横、斜め方向に連続している部分に同じラベルを振る 8 近傍処理を用いて行う。



(a) 対象の画像 (b) ラベリング処理を施した画像

図 6 ラベリング処理の例

Fig. 6 An example of labeling process

### 4.3 外観汚損の分類

外観汚損の分類には、画像のクラスを高精度で分類することが可能である CNN を用いる。CNN は現在多くのモデルが提案されており、大規模なデータで高精度な分類を行うモデルはパラメータ数も膨大である。本研究が対象としている洋ナシでは、ImageNet [23] のような大規模なデータセットの構築は困難であり、より小規模なモデルかつ高精度なモデルを用いることが重要である。これらのことから本研究では、シンプルなアーキテクチャながら高精度な分類が可能であり、現在でも多くの研究のベースラインとして利用されている VGG16 [24] を用いる。

外観汚損の分類を行うモデルを構築するために、3 節で述べた画像データを用いた。洋ナシの専門家 3 名の協力の下、洋ナシ画像に対してアノテーションを行い、表 2 に示すデータセットを構築した。図 7 に構築したデータセットの例を示す。なお、CNN の学習時にはモデルの入力次元に合わせるために 224×224 ピクセルにリサイズして使用する。

表 2 外観汚損のデータセット

Table 2 Data set of appearance deterioration

外観汚損種類	枚数
黒斑病	172
外傷痕	500
斑点状汚損	500
面状汚損	150
葉斑	500
計	1822

表 2 のデータセットに対して、事前に ImageNet で学習させた VGG16 をファインチューニングした。ファインチューニングの学習を行う際は、データセットの全体の 75%(1366 枚) を学習データ、25%(456 枚) を検証データと

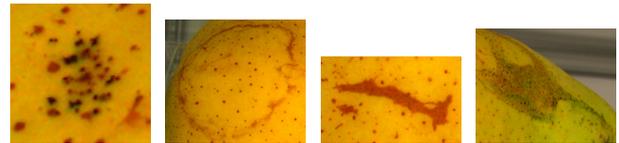


図 7 外観汚損の例

Fig. 7 Examples of pear deterioration

した。学習時には学習データを 90° ごと回転させ、データ数を 4 倍 (5464 枚) とした。学習率を 0.005、バッチサイズを 32、エポックを 25 として学習、検証を行った。学習の結果、表 3 に示す結果を得た。

表 3 CNN による分類結果

Table 3 Classification results by CNN

汚損名 \ 指標	正解率 (%)	適合率 (%)	再現率 (%)	F1
黒斑病	63.64	84.85	63.64	0.73
外傷痕	85.60	90.68	85.60	0.88
斑点状汚損	91.20	79.17	91.20	0.85
面状汚損	72.22	83.87	72.22	0.78
葉斑	94.40	91.47	91.40	0.93
平均	81.41	86.01	81.41	0.83

## 5. サービス実装

画像処理を用いたモデルを一般ユーザーに利用できるサービスとして実現する方法としては、撮影したデータを撮影した端末で処理するエッジデバイスによるもの [25] と撮影したデータをクラウド上のサーバで処理するものがある [26]。画像処理には GPU を用いた演算が不可欠であり、エッジデバイスを用いてシステムを構築するためには、個々のデバイスが高価になるため本研究の対象としては、使用デバイスに高スペックを搭載する必要がないクラウドでのサービスが適していると考えられる。

本研究で提案するサービスでは、Android アプリを実装し、Android アプリからクラウドに通信を行い、クラウド上のサーバで検査を行う。以下では、実装したサービスについて述べ、実装したサービスを用いて洋ナシの外観汚損を検査した結果について述べる。図 8 に外観検査を行う時の提案サービスの概要を示す。

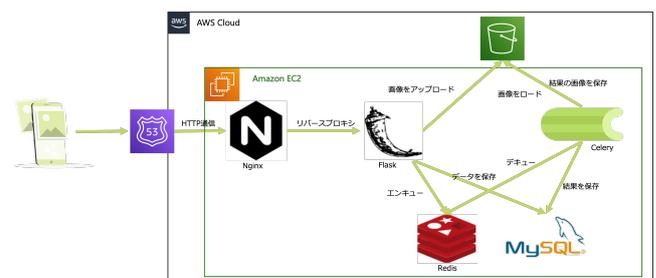


図 8 サービスの概要 (検査時)

Fig. 8 Service overview

## 5.1 Android アプリ

本提案を実装するに辺り、携帯端末として Android のタブレット端末を用い、その上にアプリケーション（以下、Android アプリ）を実装した。本節では、実装した Android アプリについて述べる。Android アプリは Android Studio 2020.3.1 を用いて Kotlin(version 1.5) で記述した。アプリは Lenovo 社の Tab P11 Pro にインストールし、検証を行う。アプリの機能は以下の通りである。

- 洋ナシの画像を撮影し、検査を行うクラウドサーバーに送信する機能
- 検査結果を表示する機能
- 過去に検査した洋ナシの一覧を表示する機能

なお、撮影される画像は 3000×4000 ピクセルの RGB 画像である。図 9 に Android アプリの画面例を示す。図 9 で表示されている画像は、実際の洋ナシではなく、レプリカのものを表示している。



図 9 Android アプリ上の画面例

Fig. 9 A series of examples of Android application screens

## 5.2 クラウドシステム

本節では、サービス実装に用いたクラウドシステムについて述べる。クラウドのサーバーは NVIDIA 製の GPU Tesla T4 が搭載された Amazon EC2 [27] のインスタンス (インスタンスタイプ: g4dn.xlarge) 上に構築し、撮影した画像と検査結果の画像を保存するために Amazon S3 [28] を用いた。使用するソフトウェアは以下の通りである。

- Nginx
- Python (4 節の記載に加えて、Flask と Celery を使用)
- Redis
- MySQL

Nginx はアプリからの通信を受ける WEB サーバーとしての機能を持ち、アプリからの通信をリバースプロキシとして Flask に通信を行う。Flask は、提案手法を使用するための API (Application Programming Interface) としての機能を持ち、4 節で述べた提案手法を実装している他、後述する Redis, MySQL へのデータの保存, Amazon S3 に対する画像のアップロードを行う。Redis は KVS 型のインメモリデータベースであり、検査をバックグラウンドで行う際のメッセージブローカの機能として利用する。MySQL は RDBMS(Relational DataBase Management System) の一つであり、検査結果の保存や Amazon S3 のデータの保存

先等のデータを保存する。

## 5.3 サービスの検証

本節で提案したサービスを用いて、2021 年 11 月に新潟県三条市で収穫され、1 ヶ月間追熟した洋ナシを対象に検証を行った。アプリを使用した検査は著者らの研究室にて行い、背景に暗幕を使用することで、画像内に洋ナシ以外が映らない状態で行った。図 10 に検査を行った結果の画像例を示す。図 10 中の右の洋ナシを確認すると黒斑病が精度高く検出できていることが分かる。また、図 10 中の中央の洋ナシを確認すると画像中央下部に斑点状汚損が広く存在しているが、汚損の中の一部のみしか検出できていないことが確認できる。画像内に洋ナシではない場所に汚損を検出してしまっている箇所が存在するが、これには洋ナシの輪郭抽出が実際の洋ナシよりも大きく抽出されていることが考えられる。

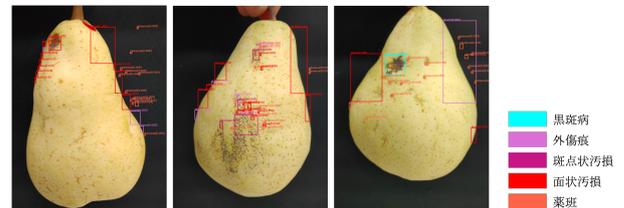


図 10 Android アプリで撮影した画像をクラウドで検査した検査結果の例

Fig. 10 Examples of test results from images taken with the Android app and inspected in the cloud server

## 5.4 考察

前項では、本論文で提案する洋ナシの外観汚損検査サービスの検証を行ったが、上述した通り外観汚損が精度良く検出されている箇所もあるが、外観汚損の中で一部しか検出がされていない汚損も存在している。これは、4 節で用いたデータセットが照明条件を調整した撮像装置を用いて工業用カメラを用いて撮影したのに対し、Android アプリで撮影された画像を用いて検査を行ったことにより、撮影環境の差が生まれたことが原因であることが考えられる。Android アプリケーションを用いて各農家が検査を行う場合には、様々な照明環境下で撮影されることが想定される。そのため、異なる機種や照明条件下で撮影された場合においても、高精度な検出を行えるように環境差を減らす前処理が必要だと思われる。

また、本提案手法の外観汚損検出のアルゴリズムは計算量が多く、GPU を用いた計算においても 1 果実 (3 画像) を検査するのに 30 秒程度の時間を要する。検査の速度を向上させるためには、検査アルゴリズムの並列化や外観汚損検出で用いている GLCM の計算時に使用する画素の範囲を小さくする等の工夫が考えられる。

## 6. まとめ

本論文では、洋ナシの外観汚損を検査するための手法を提案した後、Androidアプリとクラウドサービス上のモデルを用いた外観汚損の検査サービス実装と実際の洋ナシを用いた検証結果を述べた。提案するサービスにより、Androidアプリを用いて手軽に検査を行うことができることが示された。また、提案サービスを用いることで、現在目視で行っている外観汚損の検査を簡略化できるだけでなく、各農家での外観汚損のデータを蓄積することにより、洋ナシの栽培過程で発生する外観汚損を減少するためのデータとして用いることができると考える。

今後は、本論文内で課題となっている、外観汚損検査の速度改善及び精度の向上を行うとともに、各農家が行っている等級の観点を数値化することにより、外観汚損の検査だけでなく、等級の判定を行うことができるサービスを開発する。

**謝辞** 洋ナシデータ収集に御協力頂いた、東日本電信電話株式会社の関係各位、並びに高野果樹園の高野弘明氏に謝意を表す。

## 参考文献

- [1] 農林水産部食品・流通課：ルレクチエの出荷規格，新潟県庁（オンライン），入手先（<https://www.pref.niigata.lg.jp/uploaded/attachment/145948.pdf>）（参照 2021-12-21）。
- [2] 後藤悟史，麻生稔彦，宮本文穂：画像処理とパターン認識手法を利用した耐候性鋼材のさび外観評価，土木学会論文誌F，Vol. 62，No. 4，pp. 674-683（オンライン），DOI: 10.2208/jscejf.62.674（2006）。
- [3] 中村賢治，児玉直樹，竹内裕之，川瀬康裕：MRIのテクスチャ特徴量を用いた健忘型軽度認知障害の検出方法，生体医工学，Vol. 50，No. 1，pp. 12-22（オンライン），DOI: 10.11239/jsmbe.50.12（2012）。
- [4] 斎藤卓，清松悠，大嶋佑介，今村健志：テクスチャ画像解析の医学応用，日本応用数理学会，Vol. 26，No. 2，pp. 253-267（2016）。
- [5] Komal, K. and Sonia: GLCM Algorithm and SVM Classification Method for Orange Fruit Quality Assessment, *International journal of engineering research and technology*, Vol. 8（2019）。
- [6] Malini, S. S. and Jeyalakshmi, T. R.: Detection of Unhealthy Region of Plant Leaves Using Texture Features（2019）。
- [7] 奥山潤一，三橋渉：局所テクスチャ特徴を用いた画像解析，信学技報，Vol. 99，No. 609，pp. 67-72（2000）。
- [8] Haralick, R. M., Shanmugam, K. and Dinstein, I.: Textural Features for Image Classification, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, No. 6, pp. 610-621（online），DOI: 10.1109/TSMC.1973.4309314（1973）。
- [9] Kim, A. G., Burks, T. F., Qin, J. and Bulanon, D. M.: Classification of grapefruit peel diseases using color texture feature analysis, *Int J Agric & Biol Eng*, Vol. 2, No. 3（2009）。
- [10] Indriani, O. R., Kusuma, E. J., Sari, C. A., Rachmawanto, E. H. and Setiadi, D. R. I. M.: Tomatoes

- classification using K-NN based on GLCM and HSV color space, *2017 International Conference on Innovative and Creative Information Technology (ICITech)*, pp. 1-6（online），DOI: 10.1109/INNOCIT.2017.8319133（2017）。
- [11] Liakos, K. G., Busato, P., Moshou, D., Pearson, S. and Bochtis, D.: Machine Learning in Agriculture: A Review, *Sensors*, Vol. 18, No. 8（2018）。
  - [12] Singh, A. K., Ganapathysubramanian, B., Sarkar, S. and Singh, A.: Deep Learning for Plant Stress Phenotyping: Trends and Future Perspectives, *Trends in Plant Science*, Vol. 23, No. 10, pp. 883-898（2018）。
  - [13] Hu, K., Wang, Z., Coleman, G., Bender, A., Yao, T., Zeng, S., Song, D., Schumann, A. and Walsh, M.: Deep Learning Techniques for In-Crop Weed Identification: A Review（2021）。
  - [14] Nakano, K.: Application of neural networks to the color grading of apples, *Computers and Electronics in Agriculture*, Vol. 18, pp. 105-116（1997）。
  - [15] 川崎雄介，宇賀博之，鍵和田聡，彌富 仁：Convolutional Neural Networksを用いたウイルス性植物病害自動診断に向けた基礎検討，日本知能情報ファジィ学会ファジィシステムシンポジウム講演論文集，Vol. 31，pp. 391-394（2015）。
  - [16] da Costa, A. Z., Figueroa, H. E. and Fracaroli, J. A.: Computer vision based detection of external defects on tomatoes using deep learning, *Biosystems Engineering*, Vol. 190, pp. 131-144（2020）。
  - [17] He, K., Zhang, X., Ren, S. and Sun, J.: Deep Residual Learning for Image Recognition, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778（online），DOI: 10.1109/CVPR.2016.90（2016）。
  - [18] Zhou, H., Zhuang, Z., Liu, Y., Liu, Y. and Zhang, X.: Defect Classification of Green Plums Based on Deep Learning, *Sensors*, Vol. 20, p. 6993（online），DOI: 10.3390/s20236993（2020）。
  - [19] Yadav, S., Sengar, N., Singh, A., Singh, A. and Dutta, M. K.: Identification of disease using deep learning and evaluation of bacteriosis in peach leaf, *Ecological Informatics*, Vol. 61, p. 101247（2021）。
  - [20] Otsu, N.: A Threshold Selection Method from Gray-Level Histograms, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 9, No. 1, pp. 62-66（online），DOI: 10.1109/TSMC.1979.4310076（1979）。
  - [21] Suzuki, S. and be, K.: Topological structural analysis of digitized binary images by border following, *Computer Vision, Graphics, and Image Processing*, Vol. 30, No. 1, pp. 32-46（online），DOI: [https://doi.org/10.1016/0734-189X\(85\)90016-7](https://doi.org/10.1016/0734-189X(85)90016-7)（1985）。
  - [22] 中澤健介，山崎達也：画像処理を用いた洋ナシ果実の外観汚損の検出の研究，2021年信学会総合大会，No. D01201（2021）。
  - [23] Lab, S. V., University, S. and University, P.: ImageNet, Stanford Vision Lab and Stanford University and Princeton University（online），available from（<https://image-net.org/>）（accessed 2021-12-21）。
  - [24] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*（2015）。
  - [25] Khan, A., Nawaz, U., Ulhaq, A. and Robinson, R. W.: Real-time plant health assessment via implementing cloud-based scalable transfer learning on AWS

- DeepLens, *PLOS ONE*, Vol. 15, No. 12, pp. 1–23 (online), DOI: 10.1371/journal.pone.0243243 (2020).
- [26] Ampatzidis, Y., Partel, V. and Costa, L.: Agrovie: Cloud-based application to process, analyze and visualize UAV-collected data for precision agriculture applications utilizing artificial intelligence, *Computers and Electronics in Agriculture*, Vol. 174, p. 105457 (online), DOI: <https://doi.org/10.1016/j.compag.2020.105457> (2020).
- [27] Inc, A. W. S.: Amazon EC2, Amazon Web Services Inc (online), available from <https://aws.amazon.com/jp/ec2/> (accessed 2021-12-21).
- [28] Inc, A. W. S.: Amazon S3, Amazon Web Services Inc (online), available from <https://aws.amazon.com/jp/s3/> (accessed 2021-12-21).