

推薦コンシューマ・サービス論文

# 洋ナシ果実を対象とした外観汚損検査サービスの開発

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

受付日 2022年2月21日, 採録日 2022年6月20日

**概要:** 新潟県の名産品である洋ナシ「ル レクチエ」は、ギフトやお歳暮での需要から外観品質が重要な果実である。ル レクチエはその外観品質により判定される等級が出荷規格として新潟県により定められている。現在、この等級判定は農家自身の目視により行われており、等級判定結果の個人差や作業量の負担が課題となっている。本研究では、農家の目視に代わる等級判定システムの開発を目的としている。これまで、ル レクチエの外観画像から統計的テクスチャ特徴量を用いて外観汚損箇所を検出し、畳み込みニューラルネットワークを用いて検出された汚損の要因を分類する手法を提案することで、画像の入力から外観汚損の分類結果までをワンストップで検査するシステムを構築してきた。本論文では、構築したシステムをクラウド環境で実装することにより、作業スペースの限られている農家の作業場でタブレット端末を用いて、簡易に外観汚損の検査を行うことができるサービスを実現した。

キーワード: 深層学習, 画像処理, クラウドコンピューティング, 洋ナシ外観検査

## Development of an Appearance Deterioration Inspection Service for Pear Fruits

KENSUKE NAKAZAWA<sup>1,a)</sup> TATSUYA YAMAZAKI<sup>2,b)</sup>

Received: February 21, 2022, Accepted: June 20, 2022

**Abstract:** The pear “Le Lectier”, which is a specialty product of Niigata Prefecture, is valued by its appearance quality due to demand for gifts. The grade of Le Lectier is determined by the quality of the appearance regulation that is set as the shipping standard by Niigata Prefecture. Currently, this grading is done visually by the farmers themselves. As a result, differences in judgment results among farmers and the burden on farmers have become issues. Therefore, this study aims to develop an alternative grading system for farmers visual inspection. We have ever developed a one-stop inspection system from pear images to appearance deterioration classification, where deterioration of appearance is detected by statistical texture features and the detected deterioration is classified as one of several factors by a convolutional neural network. In this paper, we implement the system in a cloud computing environment as a service. Using this service, farmers can inspect the appearance of Le Lectier by using a tablet device even in their limited working spaces.

**Keywords:** deep learning, image processing, cloud computing, appearance inspection of pears

### 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)

<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, Niigata 950-2181, Japan

<sup>2</sup> 新潟大学工学部工学科  
Faculty of Engineering, Niigata University, Niigata 950-2181, Japan

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

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

は、新潟県の推進する「にいがたフード・ブランド」の1つとしての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

本論文の内容は2022年1月の第115回GN・第33回CDS・第30回DCC合同発表会で報告され、コンシューマ・デバイス&システム研究会主査により情報処理学会論文誌コンシューマ・デバイス&システムへの掲載が推薦された論文である。

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 斑点状汚損	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




図 1 外観汚損の例

Fig. 1 Example of pear deteriorations.

して新潟県により定められている。外観汚損の種類は図 1 に例を示すように、細菌が原因で発生し、黒く密集した点および窪みをともなう「黒斑病」(図 1(a)), 生育過程や農作業中の外部からの衝撃により発生した傷跡に生じる「外傷痕」(図 1(b)), 湿害や菌の発生により緑褐色や黒色を帯びる「斑点状汚損」(図 1(c)), 農薬の付着が原因で褐色や黒色でリング状のコルク層となる「葉斑」(図 1(d)), 湿害が原因で面状に発生する「面状汚損」(図 1(e)) である。

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自体の負担が課題となっている。現在では、新潟県による等級判定の目合わせ実施や、出荷時の別農家による 2 段階での判定といった個人差を減らすための取組みが行われている。

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、および判定基準の統一化を目的とした外観品質評価システムの構築を目指している。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、スペースが限られた生産者自身の作業場で、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、クラウドサービス上に構築されたシステムにより、撮影された洋ナシ画像から外観汚損の検査を行うサービスを提案する。

以降、2 章で関連研究について述べる。3 章で学習に使用するデータセットについて述べ、4 章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 章で提案手法を実装したサービスについて述べた後、6 章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、テキスト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。本章では、提案手法に関する関連研究について述べる。

### 2.1 統計的テキストチャ解析

テキスト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变化を全体的にとらえたものである。統計的テキストチャ解析とは、画像を 2 次元平面と見なし、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。統計的テキストチャ解析は医療分野や土木分野で用いられており [2], [3], [4], 農業分野でも異常検知を目的として用いられている [5], [6]。統計的テキストチャ解析としては、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 (GLRLM: Gray-Level Run Length Method) 等がある。その中でも同時生成行列は他の統計的解析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キストチャ解析手法の 1 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  $\delta = (r, \theta)$  だけ離れた点での濃度が  $j$  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。すなわち、ある濃度  $i$  の点から変位




図 2 同時生成行列の計算例 ( $r = (1), \theta = (90^\circ)$ )

Fig. 2 Example of GLCM calculation ( $r = (1), \theta = (90^\circ)$ ).

$\delta = (r, \theta)$  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形行列  $A$  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形行列が、式 (1) で表される同時生成行列  $GLCM$  となる。

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

図 2 に同時生成行列を算出する 1 例を示す。図 2(a) に  $GLCM$  を計算する対象となる、 $3 \times 3$  画素の 0 から 3 の画素値をとる画像を示す。ここで、 $r = 1, \theta = 90^\circ$  としたときの変位  $\delta = (r, \theta)$  における正方形行列  $A$  の計算結果を図 2(b) に示す。図 2(b) では、行列の縦方向 ( $i$ ) が対象の画素値、横方向 ( $j$ ) が対象の画素値から  $r = 1, \theta = 90^\circ$ 、すなわち、対象の画素値の右隣の点にある各画素がそれぞれ何回出現しているかをカウントした値である。ここまでで計算した正方形行列  $A$  を正規化した同時生成行列を図 2(c) に示す。なお、図 2(c) では、小数第 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 2(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、図 2(b) のような同時生成行列は 4 次正方形行列となる。実際には、 $r$  と  $\theta$  の値をいくつか設定し、その組合せごとに同時生成行列を計算することになる。また、その次元は対象画像の画素値の数が  $n$  であれば、 $n$  次正方形行列となる。図 2 の例では、 $n = 4$  である。

Kim ら [9] はグレープフルーツを対象とし、正常な果実と 5 つの病害の 6 クラスの分類を行うために HSI 色空間に対し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。Indriani 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 クラス分類を行った結果、正解率 100% という高い精度での分類に成功している。

## 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さかに行われている [11], [12], [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。川崎ら [14] は




図 3 洋ナシの画像例

Fig. 3 Example of pear images.

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。Costa ら [15] 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 [16] を用いて行い、94.6% の精度での分類に成功した。Zhou ら [17] 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。Yadav ら [18] は桃の葉を対象にバクテリア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。

本研究では、これらの関連研究の成果をふまえたうえで、汚損検出に  $GLCM$  を用いた統計的テクスチャ解析を行い、汚損分類に CNN を用いることで、画像入力から分類出力結果を一気通貫で行っている。

## 3. 洋ナシ画像データ

本論文内で使用する画像は、2020 年の 12 月に新潟県三条市で撮影された洋ナシ画像を用いる。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したものである。撮影時には  $90^\circ$  ごとに回転させ、1 つの果実に対し 4 枚の画像を撮影した。撮影された画像はいずれも  $1,536 \times 2,048$  ピクセルの 32 bit カラー画像である。撮影対象の洋ナシは 299 果実であり、計 1,196 枚の画像を撮影した。撮影した洋ナシ画像の例を図 3 に示す。

## 4. 提案手法

2 章の関連研究では、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 4 に示すように輪郭検出部と汚損検出部、汚損分類部の 3 つのセクションに分かれている。本章



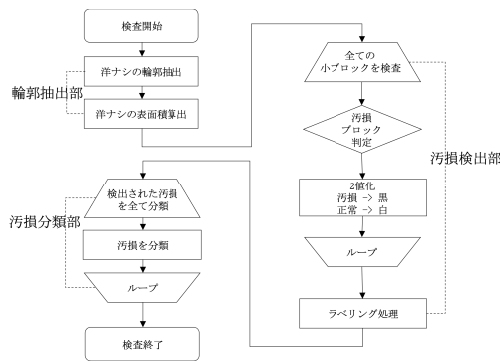


図 4 提案手法の概要

Fig. 4 Overview of the proposed method.

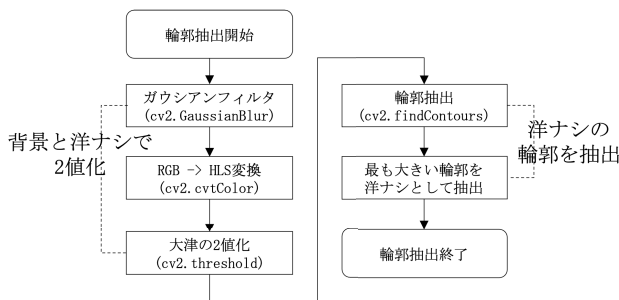


図 5 洋ナシの輪郭抽出

Fig. 5 Pear contour extraction.

では、これら 3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すべて Python (version 3.8) で記述し、使用するライブラリは以下のとおりである。

- 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) で構築された計算機環境を用いた。

#### 4.1 洋ナシの輪郭抽出

洋ナシの輪郭抽出の手順を図 5 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、RGB 色空間を HLS 色空間に変換する。色空間の変換を行った後、彩度成分を用いて大津の 2 値化 [19] を適用し、画像の 2 値化を行う。2 値化を行った画像に対して Suzuki ら [20] 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。なお、図 5 中に示す cv2 は OpenCV のことであり、OpenCV の当該関数を利用していることを示す。




図 6 ブロック画像の例  
Fig. 6 Example of block images.




図 7 ラベリング処理の例  
Fig. 7 Example of labeling process.

#### 4.2 外観汚損の検出

外観汚損の検出に用いる手法は、テクスチャ特徴量とランダムフォレストを用いた検出手法 [21] を用いる。ここで、テクスチャ特徴量を算出する際には、 $r = 5$ ,  $\theta = (0^\circ, 90^\circ, 180^\circ, 270^\circ)$  として、 $r$  および  $\theta$  の組合せで 4 通りの GLCM を算出し、式 (2) から式 (6) で定義されるテクスチャ特徴量を算出する。その後各テクスチャ特徴量で平均を求め、ランダムフォレストで利用する特徴量としている。提案手法 [21] では、図 6 に 1 例を示す洋ナシの  $32 \times 32$  ピクセル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。果点とは、果実の表面に生じる点状の模様であり、気孔等がコルク化したもので通常汚損とは見なされない。そのため検出時には、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して分類する。図 4 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行う。ラベリング処理とは、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。図 7 に示すように、同じ番号が振られたピクセルを同じ汚損として矩形で抽出することにより、外観汚損箇所を検出する。検出した外観汚損は後述するサイズにリサイズして、4.3 節で述べる CNN への入力とする。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 近傍処理を用いてラベリング処理を行う。

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	1,822

$$Contrast = \sum_i \sum_j (i - j)^2 P_{\delta}(i, j) \quad (2)$$

$$ASM = \sum_i \sum_j P_{\delta}(i, j)^2 \quad (3)$$

$$Correlation = \sum_i \sum_j P_{\delta}(i, j) \frac{(i - \mu_i)(j - \mu_j)}{\sqrt{(\sigma_i^2)}} \quad (4)$$

$$Dissimilarity = \sum_{(i,j)} P_{\delta}(i, j) |i - j| \quad (5)$$

$$Homogeneity = \sum (i, j) P_{\delta}(i, j) |i - j| \quad (6)$$

### 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、栽培されている地域が限定的である点と専門家以外ではアノテーションが困難である点から、ImageNet [22] 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 [23] を用いる。洋ナシ果実の外観汚損分類に対し、CNN を用いて行う手法は小林ら [24] によって提案されているが、そこでは VGG16 よりも階層が少ない AlexNet を用い、用いたデータセットも 3 種類の外観汚損（外傷痕、葉斑、斑点状汚損）の 477 枚のみで、最終的に約 60% の分類精度であった。

本論文では、外観汚損の分類を行うモデルを構築するために、3 章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。アノテーション対象の外観汚損は図 1 に示している外観汚損と同じであり、アノテーション時の画像のサイズは一定ではないが、CNN の学習時にはモデルの入力次元を合わせるために 224 × 224 ピクセルにリサイズして使用する。リサイズの際には、アスペクト比を考慮せずに正方形にリサイズしている。

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

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

ンチューニングの学習を行う際は、データセット全体の 75% (1,366 枚) を学習データ、25% (456 枚) を検証データとした。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 (5,464 枚) とするデータ拡張を施した。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 に示すとおり、平均正解率 81.41% での分類精度を達成している。これは、小林ら [24] の提案している手法より、分類対象のクラス数は増えているものの、データセットの拡充と CNN モデルの改良により、約 20% の精度向上を達成している。

## 5. サービス実装

画像処理を用いたシステムを一般ユーザ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方法 [26] が一般的である。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、使用するデバイスが高スペックである必要が比較的少ないクラウドで処理を行う方法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 端末上にアプリケーションを実装し、Android アプリケーション（以下、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。図 8 に外観検査を行うときの提案サービス内での処理概要を示す。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。

### 5.1 Android アプリケーション

本提案のサービス実装には、携帯端末として Android のタブレット端末を用い、その上に 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。Android アプリは Lenovo 社の Tab P11 Pro にインストールし、検証を行う。Android アプリの機能は以下のとおりである。

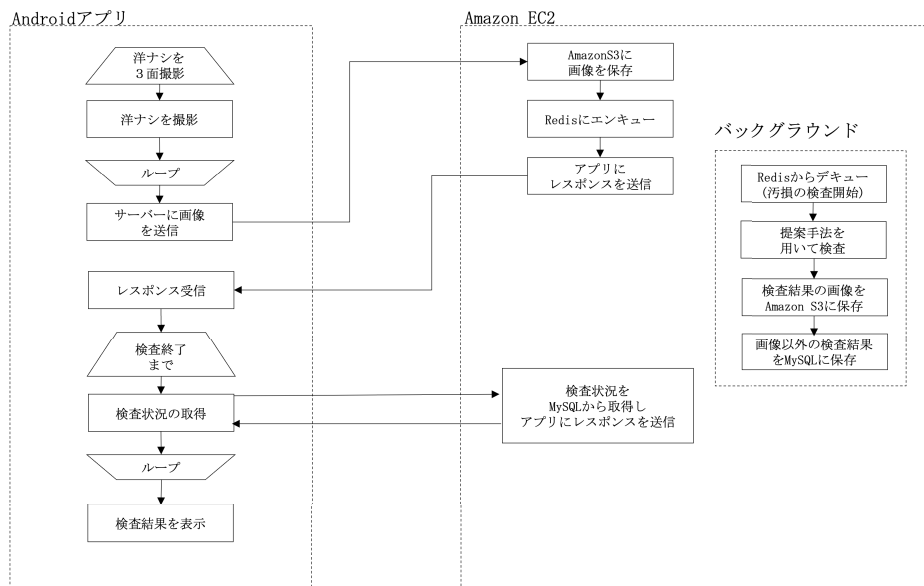


図 8 サービスの概要 (検査時)

Fig. 8 Service overview.



(a) 撮影画面 (b) 洋ナシの回転を促すメッセージ画面 (c) 洋ナシ検査結果画面

図 9 Android アプリ上の画面例

Fig. 9 Example of a screen on an Android application.

- 洋ナシの画像を撮影し、検査を行うクラウドサーバに送信する機能
- 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  $3,000 \times 4,000$  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(a) では、洋ナシを撮影する画面、図 9(b) では洋ナシを 3 角度から撮影するために回転を促すメッセージ (撮影しました 120 度回転させて再度撮影してください) を表示している画面、図 9(c) では、検査結果を示している。図 9 で表示されている画像は、実際の洋ナシではなく、レプリカのものである。

## 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とおりである。

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

Nginx は Android アプリからの通信を受ける WEB サーバとしての機能を持ち、Android アプリからの通信をリバースプロキシとして Flask を用いて構築されたアプリケーションサーバに通信を行う。アプリケーションサーバでは、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 章で述べた提案手法を実装しているほか、後述する Redis, MySQL へのデータの保存および参照, Amazon S3 に対する画像のアップロードおよびダウンロードを行う。5.5 節で述べる理由により、現状のサービスでの検査はリアルタイムでは行えないため、外観汚損検査の際には、Redis と Celery を用いた非同期処理によりバックグラウンドで検査を行っている。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 1 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

クラウド環境に構築したサービスの定性的な検証を複数の洋ナシに対して行った。4.1 節で述べた輪郭抽出を正確に行うために、背景に他の物体が入らないように暗幕を使用して洋ナシの撮影を行った。図 10 に 2 つの洋ナシに対



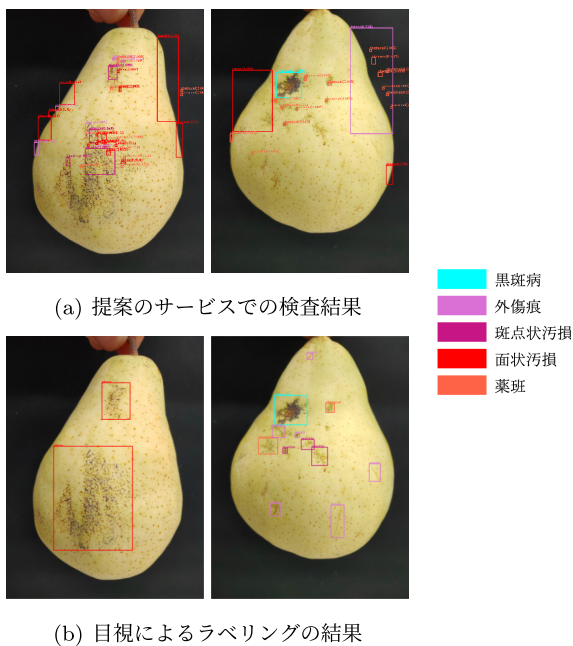


図 10 提案サービスと目視によるラベリングの比較

Fig. 10 Comparison of proposed service and human annotation.

する結果を示す。図 10(a) はシステムによる検査結果の画像であり、図 10(b) は同じ果実に対する目視によるアノテーションの結果である。図 10 の左側の洋ナシでは、図 10(b) に示すように画像中央の上部と下部に面状汚損が広く存在しているが、図 10(a) では汚損の中の一部のみしか検出できず、汚損種類の分類も異なっている部分がある。図 10 の右側の洋ナシでは、黒斑病が正確に検出されており、他の汚損部位は占める面積が小さいため、等級判定には十分な結果と言うことができる。双方とも果実の境界付近で想定外の汚損検出がされているのは、学習時にはなかった暗幕の影響が原因の 1 つと思われるが、今後の検討事項である。

#### 5.4 専門家への聞き取り調査

本論文で提案しているサービスを対象とし、11 年以上の洋ナシ栽培歴を持つ専門家 2 名に聞き取り調査を行った。聞き取り調査の結果、サービスの検査精度について現段階での実用化までは至らないが、実用化に向けた可能性を大きく感じるといった評価を得た。また、現在ではすべての洋ナシ果実に対して農家の目視により検査している。これは、表 1 に示す良よりも商品価値が低く商品性を有しない果実と商品性を有する果実の検査に同様のコストがかけられていることを示している。このことから、熟練の農家でない人が、提案するサービスを利用することで 1 次検査を行い、商品性を有しない果実を除外することにより、農家自身は検査の負担減少だけでなく、より商品価値の高い果実に対しより多くの時間を使うことができ、商品の付加価値を向上させることができる可能性があるとの意見を得た。

#### 5.5 考察

5.3 節では、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。上述したとお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されていない汚損も存在している。これは、4 章で構築したモデルには、撮影環境を調整し、工業用カメラを用いて撮影を行った 3 章で収集したデータセットを用いたが、提案サービスでは、Android アプリで撮影された画像を用いて検査を行っていることにより、撮影環境の差が生まれたことが原因であると考えられる。Android アプリ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。

5.4 節では、提案サービスに対し専門家から得た意見を述べた。本研究の目的は、農家の目視による外観品質検査を代替する外観品質評価システムの構築であるが、等級判定を行うだけでなく、農家が現状で多くの時間をかけている商品価値の低い果実の検査を代替し、果実の付加価値の向上に寄与できることが確認できた。

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、モバイル端末を利用した外観品質の検査の実現性を示すことができた。提案手法の高速化や他のウェアラブル端末の性能向上により、スマートグラスを利用した検査への可能性があると考えられる。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、外観汚損のデータを蓄積することにより、栽培過程で発生する外観汚損を減少させ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、実用化へ向けて外観汚損検査の速度改善および精度の向上を行うとともに、農家の等級判定を定量化することで、外観汚損検査に加えて等級判定まで行うサービスを開発する予定である。さらに、洋ナシ以外の日本ナシや桃といった目視による等級判定を行っている果実に対してもデータセットを構築することにより、応用が可能であると思われる。

謝辞 洋ナシ画像のデータ収集に御協力いただいた、東日本電信電話株式会社の関係各位ならびに高野果樹園の

高野弘明氏, 提案サービスに対し, 貴重な御意見をいただきました, 新潟県農業総合研究所園芸研究センターの松本辰也氏 (現, 新潟食料農業大学) ならびに根津潔氏に深く感謝いたします。

## 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 2022-06-30).
- [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, 土木学会論文集 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. and Jeyalakshmi, T.R.: Detection of Unhealthy Region of Plant Leaves Using Texture Features, *International Journal of Computer Sciences and Engineering*, Vol.7, No.8, pp.44-47 (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 Trans. 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, 2674 (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] 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).
- [15] 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).
- [16] 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).
- [17] Zhou, H., Zhuang, Z., Liu, Y., Liu, Y. and Zhang, X.: Defect Classification of Green Plums Based on Deep Learning, *Sensors*, Vol.20, No.23, 6993 (online), DOI: 10.3390/s20236993 (2020).
- [18] 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, 101247 (2021).
- [19] Otsu, N.: A Threshold Selection Method from Gray-Level Histograms, *IEEE Trans. Systems, Man, and Cybernetics*, Vol.9, No.1, pp.62-66 (online), DOI: 10.1109/TSMC.1979.4310076 (1979).
- [20] Suzuki, S. and Abe, 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: 10.1016/0734-189X(85)90016-7 (1985).
- [21] 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).
- [22] Lab, S.V., University, S. and University, P.: ImageNet, Stanford Vision Lab and Stanford University and Princeton University (online), available from (<https://imagenet.org/>) (accessed 2022-06-30).
- [23] Simonyan, K. and Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition, *3rd International Conference on Learning Representations, ICLR 2015, Conference Track Proceedings* (2015).
- [24] 小林康祐, 山崎達也: 画像解析による洋ナシ果実の外観品質評価システムの検討, 2019 年度人工知能学会全国大会, No.4H3-J-13-04 (2019).
- [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.: Agroview: 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, 105457 (online), DOI: 10.1016/j.compag.2020.105457 (2020).
- [27] AWS, Inc.: Amazon EC2, AWS, Inc. (online), available from (<https://aws.amazon.com/jp/ec2/>) (accessed 2022-06-30).
- [28] AWS, Inc.: Amazon S3, AWS, Inc. (online), available from (<https://aws.amazon.com/jp/s3/>) (accessed 2022-06-30).


## 推薦文

本論文は, 洋ナシ果実を対象にテクスチャ特徴量を用いて外観汚損部を検出し, CNN を用いて汚損要因を分類できる外観汚損検査を行えるクラウド型サービスを提案しています. タブレット端末上の Android アプリから利用でき, 作業スペースの限定的な農家の作業場でも簡易に外観汚損の検査を行えます. 本サービスによって, 洋ナシの外



観汚損状況の記録や把握を行いやすくなるため、栽培過程で生じる外観汚損を減少させる効果が期待できます。コンシューマ技術を活用して洋ナシの外観汚損検査サービスに応用した優れたコンシューマ・サービス論文として研究会より推薦いたします。

(コンシューマ・デバイス&システム研究会主査  
峰野 博史)



中澤 健介 (学生会員)

1999年生。2021年新潟大学工学部工学科卒業。同大学大学院自然科学研究科在学中。スマート農業の研究開発に従事。



山崎 達也 (正会員)

1987年新潟大学工学部情報工学科卒業。1989年同大学大学院工学研究科修士課程修了。博士(工学)。同年郵政省通信総合研究所(現、国立研究開発法人情報通信研究機構)入所。2013年8月より新潟大学工学部教授。1992～

1993年ならびに1995～1996年カナダ National Optics Institute 客員研究員。1997～2001年(株)エイ・ティ・アール環境適応通信研究所勤務。画像処理、通信品質制御、ユビキタス環境、マルチメディアサービス品質、スマート農業に関わる研究開発に従事。