

ハイブリッド深層学習モデルを用いた 果物画像からの糖度推定アプリケーションに関する検討

上野 延典^{1,a)} 本田 耕大² 森本 正志^{3,b)}

概要: 近年、食品の安全性や成分などの情報に関する消費者の需要や関心は高まっている。しかし、消費者が個々の食品情報を簡単に入手できるようにはなっていない。そこで本研究では、深層学習を用いて果物を撮影した画像からおいしさの情報を得る手法およびアプリケーションの検討を行う。本稿では果物の中で糖度がおいしさに直結しており、他の果物に比べて購入時の当たり外れが多いとされる桃を研究対象とする。提案する深層学習モデルは MLP と CNN を結合したハイブリッドモデルとなっており、桃の画像を入力することで推定糖度値を出力する。アプリケーションは iPhone で撮影した画像を AWS 上の糖度推定サーバに送信し、糖度推定値を受信し結果画面に表示する。提案したハイブリッドモデルとアプリケーションの性能評価を行い、その有効性と課題を明らかにした。

キーワード: 深層学習, ハイブリッドモデル, 果実糖度推定, iOS アプリケーション, AWS

A Study on Application for Estimating Sugar Content from Fruit Images using Hybrid Deep Learning Model

Abstract: Consumer's demand and interest about information on food safety and ingredients has been increasing recently. However, the information on individual foods can't be obtained easily. This paper proposes a method and an application for obtaining information on the taste of fruits from their images using Deep Learning. Peaches are the target of this research because their sugar content is directly related to their taste, and they are often purchased at the wrong time compared to other fruits. The proposed deep learning model is a Hybrid Model combining MLP and CNN. The model outputs an estimated sugar content value by inputting an image of a peach. The application sends the image taken by the iPhone to the sugar content estimation server on AWS, receives the estimated sugar content value, and displays it on the result screen. The performance experiments of the model and application showed the effectiveness and issues of the proposed methods.

Keywords: Deep learning, Hybrid Model, Fruit sugar content Estimation, iOS Application, AWS

1. はじめに

農林水産省は、日本人の食生活に果物を定着させて消費拡大を図る取り組みとして「毎日くだもの200グラム運動」

[1]を行っている。そこで、中央果実協会が「毎日くだもの200グラム運動」に関する取り組みとして、令和2年度の調査 [2] の中で行った果物購入時の希望情報についてのアンケートでは、「食べごろの見分け方」「おいしい果物の見分け方」のポイントが高く、消費者の果物の品質に対しての意識が高いことが分かる (図1)。また、経済産業省では、IoTなどのITを利用して消費者に鮮度情報を提示することで、流通や物流の効率化を図るという取り組みをしている [3]。このことから、消費者への食品情報の提示に対する需要や関心は高まっていると考えられる。

しかし、現段階では消費者は個々の食品のおいしさに関

¹ 愛知工業大学大学院 経営情報科学研究科
Aichi Institute of Technology Graduate School of Business Administration and Computer Science

² 愛知工業大学 (現在 NTT テクノクロス)
Aichi Institute of Technology (Currently NTT TechnoCross Corporation)

³ 愛知工業大学
Faculty of Information Science, Aichi Institute of Technology

a) b22703bb@aitech.ac.jp

b) morimoto@aitech.ac.jp

果物について知っておきたいことは何ですか。上位3つまでお答え下さい。




図 1 果物購入時の希望情報に関するアンケート [2]

Fig. 1 Questionnaire on desired information when purchasing fruit[2]

する情報を知ることができず、見た目やPOPなどのおすすめに基づいて直感的に購入していると考えられる。また、それらの情報を簡単に知る方法やサービスは容易に入手できるようにはなっていない。また、消費者のみならず、現在生産者は農作物の採取時期の見極めを経験に頼っており、採取時期を見極めることができる生産者が減少し不足している [4]。

ここで、スマートフォンなどにより果物の外観を撮影するだけでおいしさにつながる情報を推定することができれば、消費者はよりおいしい果物を容易に入手する機会を得ることができる。また、生産者は写真を撮影するだけで果物の品質に関する情報を入手することができれば、経験がなくとも適切な採取時期を見極めることが可能になると思われる。これらのサービス実現のために重要な機能は、撮影した外観情報からそのおいしさを推定する技術である。そこで本研究では、果物のおいしさを表す情報の1つである糖度の推定手法を提案する。具体的には、スマートフォンで撮影した画像を入力として、深層学習を用いた糖度推定モデルの開発を行う。また、提案手法で開発した糖度推定モデルを組み込んだアプリケーションについて述べる。今回は、果物の中で糖度がおいしさに直結しており、他の果物に比べて購入時の当たり外れが多いとされる桃を研究対象として選択する。

本稿の構成は以下の通りである。第2章で関連研究・技術について述べる。第3章で糖度推定モデルについて提案し、第4章でその糖度推定モデルを組み込んだアプリケーションについて説明する。第5章で糖度推定モデル及びアプリケーションの評価について述べ、第6章でまとめおよび今後の課題について述べる。

2. 関連研究・技術

果物の糖度を計測する上で従来用いられてきた糖度計としては、果物を絞るなどして採取した汁を試料とし、試料に含まれる固形物の濃度を計測することで糖度を計測する屈折計が挙げられる。また、近年では果物の表面に近赤外

線を当ててセンサーで計測することで果物を破壊せずに糖度を計測する非破壊糖度計も用いられている [5]。しかし、これらの糖度計は高価なため、消費者が使用することは難しい。本研究では、安価なスマートフォンを用いた果物糖度の推定を行う。

深層学習を用いて農作物の情報を得るアプリケーションの開発に関する関連研究として、杉本らによる深層学習を用いたアボカドの追熟段階分類手法の提案 [6] がある。この研究では、アボカドの硬度をもとに追熟段階を4段階に分類し、入力画像からアボカドの食べ頃を予測している。また、入力画像に対してYOLOv3を用いてアボカドを検出してから追熟段階を推定するアプリケーションを提案している。しかし、入力画像はあらかじめ撮影しておく必要があるため、消費者が食品を購入する際に使用することは困難である。本研究ではスマートフォンのカメラを用いて、その場で利用可能なアプリケーションの開発を行う。

また、株式会社マクタアニメティによる美味しさの見える化アプリ [7] がある。このアプリでは、数種類の野菜、果物の甘味、塩味、酸味、旨味、苦味などの情報を推定することができる。しかし、RGBヒストグラムを用いた推定に留まっている。本研究では複数のヒストグラムおよび画像そのものを推定に用いることで、より精度の高いアプリケーションをめざす。

3. 深層学習を用いた糖度推定

RGBヒストグラムは前章の関連研究からも有効であると考えられるが、ヒストグラム算出において背景等の影響を受けやすい。一方、画像のそのものを用いたCNNモデルによる糖度推定は、事前検証によりその推定性能に限界があることが判明した(後述)。そこで本研究では、ヒストグラムを用いて桃の色情報から糖度推定を行うと共に、CNNで照明条件や背景などの影響を軽減した推定を行う補完処理を目的として、MLPモデルとCNNモデルを結合したハイブリッドモデルを提案する。処理概要を図2に示す。撮影された桃画像に対し、桃領域を検出した後、ヒストグラム算出を行う。このヒストグラムをMLPモデルへ、桃画像をCNNモデルへそれぞれ入力し、糖度推定値を出力する。

MLP(Multi Layer Perceptron)は、深層学習の根本的な仕組みであるパーセプトロン(ニューロンモデル)を複数の層構成にしたものである。ヒストグラム次元数はそれほど多くないことから、本研究では比較的単純なMLPモデルを採用した。具体的には、MLPモデルは全結合層とBatchNormalization[8]で構成されており、活性化関数はRelu関数を用いる。本研究では桃の表面に存在する特定色の多さが糖度に関連すると考え、RGBヒストグラムを使用する。また彩度や明度の変化も糖度の変化に関連すると考え、HSVヒストグラムを使用する。これにより、入力

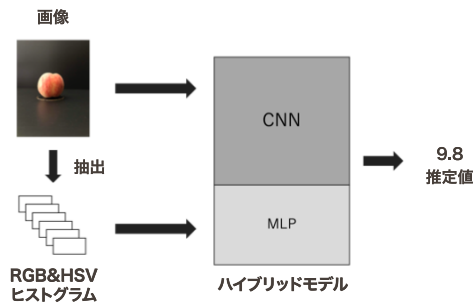


図 2 処理概要

Fig. 2 Outline of Processing

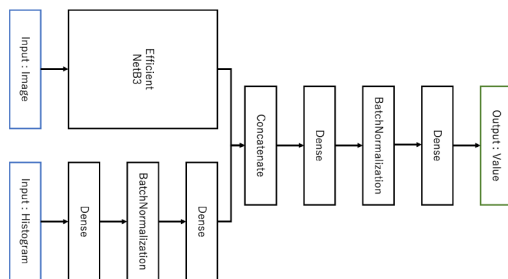


図 3 ハイブリッドモデルの層構成

Fig. 3 Diagram of Hybrid Model

ヒストグラムの 2 次元データ (6×256) となる。また、出力は 16 次元ベクトルとする。学習時間や開発環境の限界、精度を考慮し、ユニット数を 64 および 16 にした。

CNN(Convolutional Neural Network) は、畳み込み層やプーリング層を追加したニューラルネットワークである。使用する CNN モデル選定のための事前検証として、VGG16, Xception, EfficientNet[9] を用いて学習を行った。結果として推定精度に大きな違いは見られなかったものの、EfficientNet の処理速度が最も速かったことを踏まえ、本研究では EfficientNet を用いる。具体的には EfficientNetB0 から B7 のうち、パラメータ数と学習時間、imagenet での精度のバランスを考え、384 層構成の EfficientNetB3 を選択し、imagenet で学習済みモデルの上位層 56 層をファインチューニングする。

ハイブリッド化するための層構成として、本研究では前述したそれぞれのモデルから得られた特徴量を連結した 1552 次元ベクトルを入力とする全結合層 2 層と Batch-Normalization の全 3 層からなる結合層を構築し、1 つの糖度推定値を出力する。学習フェーズでは構築した結合層と MLP モデル、CNN モデルの学習を同時に行う。モデルの層構成を図 3 に示す。

4. 糖度推定アプリケーション

4.1 概要

本研究では糖度推定アプリケーションを iOS 上で作成し、糖度推定用のサーバと通信を行うシステム構成とする。




図 4 システム構成

Fig. 4 System Configuration




図 5 アプリケーションにおける処理の流れ

Fig. 5 Processing Flow of the Application

システム構成を図 4 に示す。アプリケーションの開発には Swift を使用した。また糖度推定用サーバの構築には、サーバやストレージ機能などを提供するクラウドコンピューティングサービスである AWS (Amazon Web Services)[10] を使用した。使用したプログラミング言語は Python であり、フレームワークとして、高速な API の構築が可能な FastAPI[11] を使用した。アプリのデザインはグラフィックデザインソフトである Adobe Illustrator を用いて行った。以下、アプリケーションの各機能について説明する。

4.2 写真撮影・トリミング機能

図 5 に処理の流れを示す。まず、アプリケーションを立上げるとホーム画面が表示される (図 5(a))。ホーム画面中心にあるボタンをクリックすることで、写真撮影画面に移行する (図 5(b))。写真撮影機能を実装するにあたって、音声・動画などのメディアの再生や作成、編集を行うことのできるフレームワークである AVFoundation を使用している。シャッターボタンを押して写真を撮影することで、撮影した画像に対してトリミングを行う画面に進む (図 5(c))。トリミング画面では、手動で矩形を調整することで桃の領域をトリミングすることができる。トリミング機能に関しては、iOS でユーザーが画像のトリミングを行う機能を提供するライブラリである TOCropViewController を使用した。その後、トリミング済みの画像サイズを 750×1000 に自動整形して糖度推定サーバに送信する。

4.3 糖度推定機能

AWS の仮想サーバ提供サービスである EC2 を使用し




図 6 糖度推定サーバにおける処理の流れ

Fig. 6 Processing Flow of Sugar Content Estimation Server

て構築した糖度推定サーバでは、受信した撮影画像から RGB・HSV ヒストグラムを算出して撮影画像とともに学習モデルに入力し、推定結果を iOS アプリに送信する。糖度推定機能の開発には、FastAPI を使用した。また、アプリケーションサーバとして uvicorn[12] を使用した。糖度推定サーバにおける処理の流れを図 6 に示す。

糖度推定に用いるモデルは第 3 章で述べたように、画像を入力とした CNN モデルと、ヒストグラムを入力とする MLP モデルを用いたハイブリッドモデルである。なお、学習プロセスは GoogleColaboratory[13] 上で tensorflow, keras を用いて行い、その後 AWS にデプロイする。

4.4 結果表示機能

サーバから推定糖度を受け取ることで結果画面が表示される (図 5(e))。結果画面では、受信した推定糖度が表示されるほか、送信した画像が表示される。また、推定糖度がどの程度の甘さなのかをテキストと桃のポリゴン画像で表現している。図 7 は結果画面の例である。テキストは糖度によって三段階に評価を分けている。評価は甘い！・すこし甘い・苦い…の 3 種類である。ポリゴン画像は糖度によって 5 段階に評価を分けており、ポリゴン画像に影をつけることで糖度の量を表現している (図 8)。なお、結果画面の下部に位置する「タイトル画面に戻る」ボタンを押すことでホーム画面に戻る。

5. 評価実験

5.1 実験データおよび前処理

はじめに、糖度推定モデルの学習時に使用した入力データについて述べる。画像は iphone で撮影を行い、画像背景として黒色・緑色のシート・段ボールの 3 種類を用意した。画像例を図 9 に示す。また、照明条件としては ML-CROMA2[14] を用いて、白色光と暖色光の 2 種類を用意した。桃の糖度計測は図 10 に示す糖度計 Pen-J[15] を用い、画像撮影と同じ方向の桃表面で行なった。なお、計測



図 7 結果画面の例

Fig. 7 Examples of Result Screen



図 8 ポリゴン画像

Fig. 8 Polygon Images




図 9 撮影画像例

Fig. 9 Captured Image Examples

された糖度は 6~20 程度の範囲であり、平均値は 11.1 であった。

糖度推定モデルに関して、まず桃 128 個を用いて撮影した黒色背景の計 10240 セットのデータを使用してモデルの学習を行った。次に、そのモデルに対して、桃 30 個を用いて撮影した緑色のシート及び段ボールを画像背景とした、計 14400 セットのデータを用いてファインチューニングを行うことで汎化性能向上を図った。

学習時において、桃の矩形領域抽出には画像背景が黒色とそれ以外の背景とで別の処理を行った。黒色背景画像の場合、HSV 色空間で条件式 (1) による処理を行い、マスク処理をする。次に輪郭検出を行い外接矩形を求める。更に外接矩形を一回り拡大して上下左右に余裕を持たせることで、マスク処理で抽出できなかった桃の範囲を含める。



図 10 Pen-J[15]
Fig. 10 Pen-J[15]




図 11 領域抽出の流れ (カラー背景)

Fig. 11 Bounding Box Extraction Flow (in case of color background)

$$(H < 40 \parallel 140 < H) \ \&\& \ (S > 50) \ \&\& \ (V > 70) \quad (1)$$

次に、黒色背景以外の場合は、対象画像に対し Canny 法による桃のエッジ検出、ノイズ除去を行った後、面積を求めてノイズを除去し、モルフォロジー変換を行うことで大まかな桃の領域を抽出した。その後、黒色背景の場合と同様に桃の矩形領域を抽出する。図 11 はエッジ検出から領域抽出までの大まかな流れを表している。抽出した領域の色情報から RGB および HSV ヒストグラムの作成を行い、MLP モデルに入力する。

一方、CNN モデルに対しては撮影画像を入力する。画像は元画像と反転画像にぼかし、ノイズ、ガンマ、拡大の水増し処理により枚数を 10 倍にした。

5.2 評価指標

本実験における評価指標は、回帰問題の一般的な指標である平均絶対誤差 (MAE)、二乗平均平方誤差 (RMSE)、決定係数 (R^2) を用いた。式 (2) から式 (4) に各指標の式を示す。

$$MAE = \frac{1}{N} \sum_i^N |y_i - \hat{y}_i| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_i^N (y_i - \hat{y}_i)^2} \quad (3)$$

$$R^2 = \frac{\sum_i^N (y_i - \hat{y}_i)^2}{\sum_i^N (y_i - \bar{y}_i)^2} \quad (4)$$

N はデータ数、 i はデータ番号、 y_i は真値、 \hat{y}_i は推定値、 \bar{y}_i は真値の平均値を表している。

MAE と RMSE は 0 に近づくほど精度が高いといえる。また、 R^2 は 1 に近づくほど学習データと評価データの当てはまりが良いとされる。

5.3 各モデルの評価

5.3.1 CNN モデルの評価

最初に、CNN モデル単体の性能評価を行う。EfficientNetB3 について、上位層 56 層と全結合層 2 層、Batch Normalization が学習対象となる。ここでは、最上位層を削除した後、64 ユニットの全結合層と Batch Normalization と 1 ユニットの全結合層を追加し、ファインチューニングを行った。学習データとして黒色背景の 10240 セットのデータの 80% を用いて、24 エポックでファインチューニングを行う。学習後、残り 20% を評価データとして評価指標を算出する。評価結果を表 1 に示す。

表 1 EfficientNetB3 の評価結果

Table 1 Evaluation Result of EfficientNetB3

	MAE	RMSE	R2
EfficientNetB3	1.5564	1.9376	-0.0281

5.3.2 MLP モデルの評価

次に、MLP モデル単体の性能評価を行う。CNN モデルと同様に全データの 80% を学習データとしてバッチサイズ 24、24 エポックで学習を行う。1 つの値を出力にするため、MLP モデルの最上位層のユニット数を 16 から 1 に変更したモデルを使用する。学習後、全データのうちの残り 20% を評価データとして、評価指標を算出する。評価結果を表 2 に示す。

表 2 MLP モデルの評価結果

Table 2 Evaluation Result of MLP Model

	MAE	RMSE	R2
MLP	1.1791	1.5048	0.4029

MLP モデルでの各評価指標は CNN モデルより良い。この結果から特定色の多さや色の変化が糖度の変化に関連している可能性があると言える。

5.3.3 ハイブリッドモデルの評価

前述した CNN モデルと MLP モデルを結合したハイブリッドモデルの評価としては、まず黒背景のデータ全 10240 セットに対する 4 分割交差検証を行い、それぞれの評価指標を算出した。1 回の交差検証に対し 24 エポックの学習を行った。各交差検証 (テストデータ) ごとの評価結果を表 3




図 12 ハイブリッドモデルの学習過程グラフ例

Fig. 12 Learning Process Graph Example of Hybrid Model

に、学習過程グラフの例を図 12 に示す。平均は MAE が 0.4223, RSME が 0.6249, R^2 が 0.8833 となっていた。どのテストデータでも MAE が 0.5 程度, R^2 が 0.85 程度になっており、ハイブリッドモデルによる性能補完効果が表れていると考えられる。

表 3 ハイブリッドモデルの評価結果 1

Table 3 Evaluation Result 1 of Hybrid Model

テストデータ	MAE	RMSE	R2
データ 1	0.3557	0.5902	0.8875
データ 2	0.4414	0.5766	0.9222
データ 3	0.5322	0.6929	0.8516
データ 4	0.3577	0.6397	0.8718

5.4 アプリケーション化に向けたモデル評価

次に、アプリケーションとしての実用性を検証するためのモデル評価を行う。まず、これまでは桃の側面画像ごとに正解糖度を与えていたが、桃個体に対して糖度が推定されることが望ましい。そこで、各桃ごとに糖度データの平均値を求め、それを推定すべき正解データとする。学習は同じく 4 分割交差検証を用い、5.3 のデータ中から 880 枚を抜き出し、それらを水増しした計 8800 枚を用いて 24 エポックの学習を行なった。

このように学習した 4 つのモデルに対して、二通りの評価実験を行った。まず最初に、学習データとは異なる、背景が黒い画像 144 枚をテストデータとして評価を行った。評価結果を表 4 に示す。平均は MAE が 0.8795, RSME が 1.1048, R^2 が -0.1699 となった。正解データを桃ごとの平均値に変更したことで、例えば MAE が 0.45 程度低下していることがわかる。

次に、背景が黒い画像 144 枚に加えて、背景が緑色の画像と段ボールの画像を各 72 枚加えた、合計 288 枚の画像で評価を行った。評価結果を表 5 に示す。平均は MAE が 1.4863, RSME が 1.966, R^2 が -0.793 となった。異なる背

表 4 ハイブリッドモデルの評価結果 2

Table 4 Evaluation Result 2 of Hybrid Model

テストデータ	MAE	RMSE	R2
データ 1	0.9734	1.2099	-0.3985
データ 2	0.8245	1.0604	-0.0742
データ 3	0.8880	1.0949	-0.1452
データ 4	0.8322	1.0542	-0.0618




図 13 学習過程グラフの例 (データ追加後)

Fig. 13 Learning Process Graph Example (after adding data)

景色の画像を用いた場合に精度が落ちていることから、画像背景の種類を追加してファインチューニングを行うことで汎化性能の向上を図る必要があると考えられる。

表 5 ハイブリッドモデルの評価結果 3

Table 5 Evaluation Result 3 of Hybrid Model

テストデータ	MAE	RMSE	R2
データ 1	1.4794	1.9130	-0.6791
データ 2	1.6722	2.2713	-1.3670
データ 3	1.4918	1.9865	-0.8105
データ 4	1.3016	1.6932	-0.3155

5.5 データ追加後のハイブリッドモデルの評価

5.4 で学習した各モデルに対し、背景が段ボールと緑色のシートの画像各 720 枚の計 1440 枚を水増しした 14400 枚を用いてファインチューニングを行った。追加データは学習・バリデーションデータに分けて 24 エポックの追加学習を行なった。学習過程グラフの例を図 13 に示す。評価結果を表 6 に示す。平均は MAE が 1.8700, RSME が 2.3644, R^2 が -1.5750 となった。この数値は、人間の味覚で少し違いを感じるものの、桃の糖度推定値としては概ね問題ないと考えられる。一方、想定と異なりファインチューニングにより若干性能が低下している。学習画像の増強やファインチューニングの手法などの検討が必要であると考えられる。

表 6 データ追加後のモデルの評価結果

Table 6 Evaluation Result of the Model after adding data

テストデータ	MAE	RMSE	R2
データ 1	1.7418	2.2258	-1.2731
データ 2	1.9849	2.4978	-1.8626
データ 3	1.9636	2.5245	-1.9241
データ 4	1.7899	2.2097	-1.2403

5.6 アプリケーションの評価

アプリケーションの評価は、その処理速度と糖度推定精度 (5.2 の評価指標) により行う。アプリケーションの評価をするにあたって使用したデータは、5.5 と同様である。

処理速度は、iOS アプリケーションからサーバに画像を送信してから結果画面が表示されるまでとして評価を行った。評価結果を表 7 に示す。実用上は問題がないと考えられるが、推定モデルに入力する画像サイズを縮小してモデルを軽量化することでより高速になると考えられる。その場合、推定精度とトレードオフとなることが考えられるため、十分な検証が必要である。

表 7 処理速度評価結果

Table 7 Evaluation Result of Processing Speed

処理速度	分散	標準偏差
2.9768	0.0843	0.2904

推定精度評価は、5.5 で学習させた推定モデル (最も性能の良かったモデル) を用いて行なった。モデル自体の精度評価とアプリケーションにおける精度評価の条件の違いとして、アプリケーションでは桃の領域をトリミングした画像を用いて推論を行なっているという点が挙げられる。アプリケーションにおける推定精度評価結果を表 8 に示す。列挙したモデル自体の評価と比較すると、アプリケーションで推論を行った場合の精度は若干下がっている。この原因として、RGB・HSV ヒストグラム抽出における桃の領域算出が上述した通り異なるため、背景を含む度合いの違いが影響していると考えられる。

表 8 アプリケーションにおける推定精度評価結果

Table 8 Evaluation Result of Estimation Accuracy on Application

テストデータ	MAE	RMSE	R2
モデル自体の評価	1.7418	2.2258	-1.2731
アプリケーションの評価	2.0389	2.4554	-1.7663

6. おわりに

本稿では、深層学習を用いた糖度推定手法の提案と、その糖度推定モデルを組み込んだ糖度推定アプリケーションについて述べた。糖度推定モデルは MLP モデルと CNN モデルを組み合わせたハイブリッドモデルを提案し、それぞれの単体モデルに比して良い評価結果が得られた。その一方で、個体としての糖度評価や背景条件の変動に対する評価結果は、ファインチューニング後においても低下している。これより今後の課題としては、画像背景や照明条件の違いによる推定精度の低下への対処が挙げられる。例えば、撮影画像から桃の領域のみを抽出してモデルの学習に使用するデータを作成するなどの前処理手法改良が考えられる。

糖度推定アプリケーションは、Swift や AWS などを用いて開発を行った。アプリケーションの機能としては、撮影画面、撮影画像から桃の領域を矩形抽出するトリミング画面、糖度推定サーバへ画像を送信し、アプリケーションで受信した推定糖度を表示するポリゴン画像と共に表示する結果画面といったシンプルな構成とした。今後の課題としては、モデル自体の精度評価とアプリケーションを用いた場合での誤差についての問題が挙げられる。桃の領域抽出プロセスを統一することで改善が可能と考えられる。また、推定モデルの学習時と同様に、背景や照明条件が推定精度に影響を与えていると考えられるため、アプリケーションでも撮影画像から背景を含めない桃の領域のみを抽出する方法を考える必要がある。さらに、ユーザビリティ評価を行うことで利用面における課題を明確にする必要がある。

参考文献

- [1] 農林水産省: 毎日くだもの 200 グラム! (オンライン) 入手先 (https://www.maff.go.jp/j/seisan/ryutu/fruits/f_syohi/) (参照 2022-10-26).
- [2] 中央果実協会調査資料 No 256: 令和二年度 果物の消費に関するアンケート調査報告書 (オンライン) 入手先 (http://www.kudamono200.or.jp/pdf/r02anq_hokoku01.pdf) (参照 2022-10-26).
- [3] 経済産業省: 令和 3 年度流通・物流の効率化・付加価値創出に係る基盤構築事業 IoT 技術を活用したスーパーマーケットにおける食品ロス削減事業実証実験概要 (オンライン) 入手先 (<https://www.meti.go.jp/press/2020/01/20210120003/20210120003-1.pdf>) (参照 2022-10-26).
- [4] 農林水産省: 2020 年農林業センサス結果の概要 (オンライン) 入手先 (<https://www.maff.go.jp/j/press/tokei/census/attach/pdf/210427-3.pdf>) (参照 2022-10-26).
- [5] 千代田電子工業株式会社: 非破壊糖度計おいしい果 (オンライン) 入手先 (<https://oishika.net/feature/>) (参照 2022-10-26).
- [6] 杉本隼人, 久野文菜, 谷口航平, 濱川礼: 深層学習を用いたアボカドの追熟段階分類手法の提案, 人工知能学会全国大会 (第 34 回), 1F3-OS-2a-01 (2020-6).
- [7] マクタアメニティ株式会社: おいしさの見える化 (オンライン) 入手先 (<http://makuta-amenity.com/iot/>) (参照 2022-10-26).

2022-10-26).

- [8] Sergey Ioffe and Christian Szegedy : "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift", CoRR, arXiv:1502.03167, 3-16(2015).
- [9] Mingxing Tan et al. : "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks", ICML 2019, arxiv:1905.11946(2019).
- [10] Amazon.com : AWS(オンライン) 入手先 (<https://aws.amazon.com/jp/what-is-aws/>) (参照 2022-10-26).
- [11] tiangolo : FastAPI(オンライン) 入手先 (<https://fastapi.tiangolo.com/ja/>) (参照 2022-10-26).
- [12] Encode : uvicorn(オンライン) 入手先 (<https://www.uvicorn.org>) (参照 2022-10-26).
- [13] GoogleLLC : GoogleColaboratory(オンライン) 入手先 (<https://colab.research.google.com>) (参照 2022-10-26).
- [14] Manfrotto : MLCROMA2 色温度可変 LED ライト 900lux(オンライン) 入手先 (<https://www.manfrotto.com/global/led-light-croma2-with-gel-diffuser-and-ball-head-mlcroma2/>) (参照 2022-10-26).
- [15] ATAGO : ペン糖度計・濃度計 (オンライン) 入手先 (<https://atago.net/japanese/new/products-pen-top.php#AEG33095>) (参照 2022-10-26).
- [16] 本田耕大, 森本正志 : 深層学習を用いた果物画像からの糖度推定の研究, 令和 2 年度電子情報通信学会東海支部卒業研究発表会, 3-16(2021).
- [17] 上野延典, 森本正志 : 深層学習を用いた果物画像からの糖度推定アプリケーションの開発, 令和 3 年度電子情報通信学会東海支部卒業研究発表会, 2-1(2022).