



原 著 論 文

農業情報研究 28 (3), 2019. 108-114
Available online at www.jstage.jst.go.jp/

J-STAGE

深層学習を利用したウメ「露茜」の画像による熟度分類

建本 聡^{*1)}, 原田陽子¹⁾, 今井健司²⁾

- 1) 徳島県立農林水産総合技術支援センター 農産園芸研究課
〒779-3233 徳島県名西郡石井町石井字石井 1660
- 2) 徳島県立農林水産総合技術支援センター 資源環境研究課
〒779-3233 徳島県名西郡石井町石井字石井 1660

要旨

本研究では、深層学習による物体検出 (SSD) と熟度判定用の畳み込みニューラルネットワーク (CNN) を組み合わせて、画像からウメの果実の熟度を判断する方法を検討した。2018 年 6～7 月に、ウメ「露茜」の樹上の果実についてデジタルカメラにより静止画及び動画を取得した。果実領域を切り出すための SSD の学習は、撮影した画像 443 枚を用いた。学習したネットワークの性能は、しきい値 0.47 で、F 値 0.88 であった。次に熟度判定用の CNN の学習のため、SSD により切り出した 5,823 枚の画像を熟度別に肉眼で 5 クラスに分類し教師とした。学習したネットワークの識別の精度は 94% であった。これらを組み合わせた精度を判定するために、学習に用いていない画像から、SSD によりしきい値 0.47 で 366 枚の果実画像を切り出し、続けて画像を熟度判定用の CNN で分類したところ、識別の精度は 96% であった。よって、撮影画像から本手法により果実領域を切り出し、熟度判定が良好に行えることが示唆された。

キーワード

深層学習, 熟度判定, 物体検出, 一般物体識別, ウメ

はじめに

果樹の栽培において、適切に果実の熟度を判断することは農業経営において必須であり、作業現場での熟度判断は、主として栽培者の経験に基づいて行われている。しかし、生産者が収穫期の判断を主観でおこなうことは、品質のばらつきの原因となり、経験が不足している新規就農者では、適切な熟度判断が最も困難な作業のひとつである。一方、このような問題を解決するため、収穫適期判断用のカラーチャートが作成されている。しかし、カラーチャートは新品種や栽培面積の小さい品種で作成が進んでおらず、さらに栽培品種ごとの購入が必要となる。また、カラーチャートは、屋外の使用による劣化等、継続的な使用に問題がある。

このような問題に対して、果実のデジタル画像を取得することで熟度を画像から判定可能となるアプリケーションの開発が進んでいる。このアプリケーションを用いることで、収穫時期を客観的なデータとして取り扱うことができ、産地での収穫時期の情報共有が可能となる。これまでも、撮影した画像から果実の熟度を判定する試みは多数あり、は場に備え付けたカメラから RGB 値を求め、リンゴ園地ごと偏りを補正しその比率により判断する方法 (岸ら 2010)、リンゴ果実の着色を補正用カラーチャートを用いることで屋外の光条件の違いを補正し判定する方法 (草田ら 2016) がある。また、屋外では、果実の判別精度を向上させるためには、葉や茎の影響を除外し果実のみを抽出する必要があるため、カラー画像のヒストグラムを解析し、キュウリの葉の領域を抽出する方法が提案されている (小川, 酒井 2009)。しかし、これまでの手法は、人為的に特徴量の抽出を行っており、複雑な前処理や特別な撮影補助器具を用いる必要があり、自動化されていない変換や補正

* Corresponding Author
E-mail: tatemoto_satoshi_1@pref.tokushima.jp

が必要である。また、これらの手法は、想定する画像及び環境でのみうまく動作し、少しでも想定外のことがあると動作が安定しないといった問題がある(松尾 2015)。特に光条件が多様に変化する屋外では、精度が低下しやすく、既存の画像識別手法は、精度の向上と動作の安定性を両立することが困難であった。

しかし、近年、画像認識のコンテストにおいて、これらの問題の解決が可能な深層学習の手法が導入されており、認識精度でも上位を独占している(中山 2017)。深層学習では、人間が利用条件ごとに複雑な前処理のアルゴリズムを作成せず、機械が大量のデータからネットワークのパラメーターの重み付けの学習を行うため、様々な画像で頑健に動作する。また、深層学習を用いた分類器の作成に必要なライブラリは、オープンソースで利用できる(浅川 2016)ため、分類器の作成は、市販のプログラムを購入することなく、安価に開発できる。

深層学習による画像解析には、畳み込みニューラルネットワーク(Convolutional Neural Network: CNN)による画像分類(Krizhevsky et al. 2012)や、物体検出にCNNを用いた、SSD(Single Shot MultiBox Detector)(Liu et al. 2016)やYOLO(You Only Look Once)(Redmon et al. 2016)等の手法がある。画像分類とは、画像から物体の属性を判定する技術であり、物体を分類する精度は、人間の認識能力を超え、98%であるものも報告されている(中山 2017)。一方、物体検出とは、画像の中から物体を検出する技術であり、深層学習を用いたSSDでは、多クラスの検出精度は74% mAP(mean Average Precision: クラスごとの物体検出の精度(%))の平均値)であることが報告されている(Liu et al. 2016)。YOLOは、大まかに定義したグリッドに沿って物体検出をしているため、物体のスケールの変化に弱く、SSDは、各畳み込み層から物体矩形と物体カテゴリーのスコアを出力させることで、スケール変化に頑健な物体検出を実現している(藤吉, 山下 2017)。本報告の物体検出には、屋外のサイズの異なる果実をより高い精度で検出するため、SSDを用いた。農作物の物体検出や熟度判定に深層学習を用いた例としては、マンゴーやリンゴ、アーモンドの樹上の果実の検出にFaster R-CNNを用いた例(Bargoti and Underwood 2017)、トマトの熟度判定のために、果実画像を抽出し、熟度ごとに5段階に分類し5層のCNNで91.9%の精度で分類した例(Zhang et al. 2018)などがある。

本報告では、ウメ品種「露茜」を用いた画像による果実の検出と熟度の判定を試みた。「露茜」は、ウメとスモモの属間品種であり、通常のウメと異なり赤色に着色する(八重垣ら 2012)。輸送時にも果実の追熟が進むため、出荷形態によって色調を判断しながら収穫する必要があり、画像による熟度判定に適していると考えたため実験に用いた。物体検出及び熟度のカテゴリー分類はSSDのみで可能であるが、SSDのアノテーションには多大な労力が必要となり(Adhikari et al. 2018)、類似した物体についてはカテゴリーの分類誤りが多いことが示されている(Liu et

al. 2016)。本研究のような、形状が類似し色調が連続的に変わる果実の熟度の判定をSSDのみで行うことは難しいと考えられた。一方、SSDの精度を向上させる試みとして、画像から大豆の花を計数するために、SSDで花の領域を抽出したのち、その領域を精査用のCNNで花かどうかを識別し精度を向上させた例(大村ら 2018)が報告されている。加えて、CNNの学習において、同一画像上に学習対象以外の物体があると、それを特徴量として学習し分類精度が低下する(梅田 2018)ことが指摘されている。SSDで先に果実領域のみを抽出し画像上の不要な情報を除去することは、熟度判別用CNNの誤学習の防止にも有効である。これらの理由により本報告では、ウメ「露茜」の画像による果実熟度判定にSSDと熟度判別用CNNを組み合わせ、その精度を検証した。

果実の熟度判別システムの開発

材料と方法

画像の撮影方法及び学習条件

画像及び動画の撮影は、デジタルカメラ(Nikon I V1, Nikon I J2, Pentax K20)、スマートフォン(Huwei-P10 lite)を使用した。撮影は、徳島県板野郡上板町のウメ栽培場で22本の樹を対象に2018年の6月～7月にかけて、午前中や午後、曇天や晴天など多様な光条件のもとで行った。果実は、未着色から完全に着色したステージにおいて様々なステージが含まれるように果実に近接して撮影した。動画の撮影は、対象物を中心にカメラを回転させ多様な角度の果実が含まれるように行った。動画の切り出しは、1/4～1/30秒(99%は1/6秒)で行った。撮影は1280×720から3264×2448の画素で行った。これらのことにより、適度のばらつきがあるデータセットになるように配慮した。ニューラルネットワークの学習は、GPU(GeForce GTX1050Ti NVIDIA社製)を搭載したubuntu 16.04上のpython(Ver. 3.5)でバックエンドにtensorflow-gpu(Ver. 1.8)を用いたkeras(Ver. 2.1)で行った。

果実検出用SSDの作成

SSDの学習のため、443枚の画像を使用した。学習対象の領域座標に対するアノテーションは、焦点が合っており、果実全体が確認できる1,091果実を対象とした。画像は300×300に変換し、RGBで学習に使用した。学習は、事前に学習を行ったVGG16ネットワークを使用した転移学習で行った(Rykov 2016)。作成したネットワークの精度の判定には、学習に使用していない357枚の画像を使用した。アノテーションは、SSDの作成と同様の条件で829果実に行った。SSDの検出結果の評価は、事前にラベリングした果実と検出した果実のずれが画像上の幅10%以下であれば適正に検出できたものとした(以下、適正検出果実)。なお、SSDにより検出された領域を再度検出し

深層学習を利用したウメ「露茜」の画像による熟度分類



図1 着色カテゴリーごとの果実画像

た場合は、適正検出果実に含めなかった。これらの情報をもとに、作成したネットワークの評価を、クラス分類のしきい値ごとに、次式で計算した適合率、再現率、F値で行った。なお、SSDでは、物体の探索領域から、物体候補が領域内に存在する確信度を0～1で表す。1に近いほど精度は向上するが、検出する物体数が少なくなる。一方、0に近づけると、検出する物体数は多くなるが、精度が低下する。この0～1の範囲のうちある値以下は検出対象として用いない、この値をしきい値として定義した。

$$\begin{aligned} \text{再現率} &= \frac{\text{適正検出果実数}}{\text{目視でアノテーションした果実数}} \\ \text{適合率} &= \frac{\text{適正検出果実数}}{\text{SSDによる全検知数}} \\ \text{F値} &= \frac{2 \times \text{再現率} \times \text{適合率}}{\text{再現率} + \text{適合率}} \end{aligned}$$

熟度判定用 CNN の作成

熟度判定用 CNN の学習データは、撮影した画像から SSD により果実の領域画像を切り出し、焦点があっていないもの、極端に暗いものや明るいもの、判別が困難のものを除き、5823 枚を用いた。果実画像は、露茜の収穫経験のある 3 名の作業者によって、未着色から完全着色した果実までを露茜のカラーチャート（和歌山県 2016）を参考に 5 カテゴリーに分類した。各カテゴリーは 0% 着色（未着色）、25% 着色、50% 着色、75% 着色、100% 着色（完全着色）とした（図 1）。

学習及びテストに用いた画像は、0% 着色 1195 枚、25% 着色 1413 枚、50% 着色 962 枚、75% 着色 1163 枚、100% 着色 1090 枚であった。画像は、事前に各 50 枚をテスト用画像として除き、残りの画像を学習用、検証用の比が 8:2 になるようにランダムに分類した。ネットワークの学習は事前学習済みの VGG19 を用い、畳み込みの 17 層以降について学習を行う転移学習で行った。VGG19 とは、2015 年に発表され、19 層の畳み込み層を重ねたシンプルなネットワークである（Simonyan and Zisserman 2015）。なお、ブドウのデラウエアのジベレリンの適期判断では、VGG19 を使用した場合に最も validation-loss が低下したことが報告されている（建本 2018）。また、予備実験で InceptionV3

を用いたが、validation-loss が VGG19 に比較して減少しなかったため、VGG19 を用いた。学習は validation-loss の低下が 5 回を超えて低下しないときに打ち切った。作成したネットワークでテストデータの検証を行った。

果実検出用 SSD と熟度判定用 CNN の組み合わせ

これまでの実験で最も Validation-loss が小さくなった SSD と熟度判定用 CNN の分類器を組み合わせた場合の精度を検証した。画像は、SSD の検出精度の検証に使用した 144 枚を用い、SSD により、しきい値 0.47 で 366 果実を切り出し、熟度判定用 CNN により各カテゴリーに分類した。分類された画像を、収穫経験のある 3 名により、精度を検証した。なお、CNN では、カテゴリーごとの分類は推定所属確率で表示される。そのため、連続量である熟度を表現するため、各カテゴリーの所属確率をもとに次式に従い熟度に変換した。

熟度（Ripeness）% =

$$\begin{aligned} &0\% \text{着色} \times 0 + 25\% \text{着色} \times \frac{1}{4} + 50\% \text{着色} \\ &\times \frac{1}{2} + 75\% \text{着色} \times \frac{3}{4} + 100\% \text{着色} \times 1 \end{aligned}$$

注）○% 着色は、着色カテゴリーの所属確率を表す。

結果

果実検出用 SSD の精度

しきい値ごとの学習の精度を表 1 に示す。

最大の F 値はしきい値 0.47 で 0.88 となった。そのときの再現率は 90%、適合率は 87% となった。しきい値を 0.47 に設定した場合の画像の表示結果を図 2 に示す。おおむね、事前に付したアノテーションと一致した結果が得られており、果実のみが抽出できていることがわかる。

熟度判定用 CNN の精度

精度は、0% 着色で 98%、25% 着色で 90%、50% 着色で 88%、75% 着色で 92%、100% 着色で 100% となり、全体では 94% となった（表 2）。判定の間違ひは、前後の着色カテゴリーに限られていた。

表1 しきい値ごとの再現率, 適合率, F 値の推移

しきい値	再現率 (%)	適合率 (%)	F 値
0.00	100	3	0.063
0.10	100	42	0.594
0.20	99	65	0.784
0.30	97	76	0.851
0.40	94	83	0.879
0.41	93	83	0.876
0.42	92	84	0.875
0.43	92	85	0.879
0.44	91	85	0.881
0.45	91	85	0.881
0.46	91	86	0.884
0.47	90	87	0.886
0.48	90	87	0.884
0.49	89	87	0.879
0.50	88	87	0.878
0.60	83	91	0.870
0.70	78	93	0.846
0.80	70	95	0.805
0.90	56	97	0.708
0.99	11	100	0.202




図2 SSDによるウメ画像の検出結果の一例

注) 実線: 事前にアノテーションを行った領域
破線: SSDで検出された領域

SSDと熟度判定用CNNを組み合わせたシステムの精度及び解析例

精度は, 0%着色で99%, 25%着色で99%, 50%着色で91%, 75%着色で84%, 100%着色で98%となり, 全体で96%となった(表3)。またSSDによる検出で, 果実以外のものや, 複数の果実を切り出したものは1.1%であり, 果実1個を適正に切り出したものは98.9%となった。

SSDと熟度判定用CNNを組み合わせ, カテゴリー所属

表2 熟度判定用CNNによるカテゴリーの分類結果と目視での分類結果

		深層学習による分類					小計	精度 (%)
		未着色	25%着色	50%着色	75%着色	完全着色		
目視での分類	未着色	49	1	0	0	0	50	98.0
	25%着色	3	45	2	0	0	50	90.0
	50%着色	0	1	44	5	0	50	88.0
	75%着色	0	0	1	46	3	50	92.0
	完全着色	0	0	0	0	50	50	100.0
総数							250	93.6

表3 SSDで切り出した画像の熟度判定用CNNによるカテゴリー分類結果と肉眼での分類結果

		深層学習による分類					小計	精度 (%)
		未着色	25%着色	50%着色	75%着色	完全着色		
目視での分類	未着色	112	1	0	0	0	113	99.1
	25%着色	0	101	1	0	0	102	99.0
	50%着色	0	3	29	0	0	32	90.6
	75%着色	0	0	0	47	9	56	83.9
	完全着色	0	0	0	1	60	61	98.4
総数							364	95.9

果実以外及び複数の果実を検出(果実以外)

2 98.9[※]

注) 精度 = (総数 - 果実以外) / (総数 + 果実以外) で算出

確率を熟度に変換した例を図3に示す。おおむね抜き出し位置および熟度は妥当な結果が得られた。

考察

本研究では, 撮影前に対象品目に特化した複雑な前処理や撮影条件の再現を行うことなく, SSDと熟度判定用CNNを組み合わせ果実の熟度の判定を試みた。作成したSSDのネットワークによる果実の検出精度は, しきい値を0.47にすれば, F値は0.88となり, 検出すべき果実は, 再現率から考慮すると90%の確率で検出できた。深層学習を使用せず, SVM (Support vector machine) を利用してリンゴ果実の検出を試みた場合の検出成功率は53% (市川ら2017)と報告されており, 本検出手法はこの手法を上回っていると言える。なお, SSDは, しきい値を高くした場合は, 検出精度の向上が可能のため, より明瞭な果実画像のみを検出することも可能である。

熟度判定用CNNによる果実の着色の判定は, 全カテゴリー総合で90%以上の精度で判定が可能であった。また, 判定の間違いも前後の着色カテゴリーに限られていた。一

深層学習を利用したウメ「露茜」の画像による熟度分類




図3 熟度判定用CNNによるウメ画像の熟度判定結果

注) 図中の%は熟度を表す。

般物体認識での大規模データセットを使用した場合において人間の正答率は95%程度と評価(中山2015)しており、本検出方法は、目視と同程度の精度があると考えられる。

SSDと熟度判定用CNNを組み合わせて使用した場合は、SSDが目視で熟度判断ができない果実を検出したのは1.1%にとどまり、熟度判定用CNNによる果実の熟度判断の誤判断も4%であった。しかし、SSDによる誤判断の結果は、使用者が画像で確認できるため、無視することが可能である。これらの結果を熟度(%)で表記することで、カテゴリー区別の誤判定を小さくし、より客観的に判断可能と考えられた。

本手法は、1画像中に複数の対象果実が存在した場合でも、個別識別と熟度判定を同時に行うことが可能であり、撮影回数の低減や、遠隔モニタリングを利用した樹体全体の果実数推定や熟度判定にも有効であることが示唆された。また、本手法は、撮影条件や取得画像の制限が少ないことから、野外の使用においても、安定的な性能が期待できる。そして、深層学習を利用したネットワークは、転移学習を行うことで対象を変えた場合も転用が可能で、高精度に対象物を分類できるネットワークが作成できる。加えて、特徴の抽出を人間が行わず機械が行う深層学習は専門的な前処理も必要とせず、ライブラリはオープンソースで利用が可能であるため、より容易に開発が可能である。

つまり、本方法を実際の熟度判定に使用しつつさらに画像データを蓄積し、より大規模なデータセットで学習することで、頑健性を高め汎化性能を向上させることも期待される。

まとめ

本研究では、SSDと熟度判定用CNNを組み合わせ、果実の熟度判別を試みた。SSDはしきい値0.47で0.88(F値)となり再現率は90%であった。熟度判定用CNNによるカテゴリーの分類精度は約94%であった。SSDと熟度判定

用CNNを組み合わせた場合は、SSDで熟度判定が可能な果実を約99%抜き出しており、熟度判定用CNNでの熟度判断は96%の精度で判断できた。カテゴリーの所属確率をもとに熟度を算出した結果、人間の知覚に準じた表記が可能であった。今後は、画像データの積み重ねることにより様々な条件で安定して動作させることが可能である。

謝辞

「露茜」の栽培管理にあたり多大なるご尽力を頂いた、徳島県立農林水産総合技術支援センター農産園芸研究課以西主査、非常勤職員の皆様、果実の判別にご協力頂いた堀江氏、成川氏、板東氏に厚く御礼申し上げる。

付記

本論文の一部は、園芸学会平成30年度秋季大会において口頭報告した建本「深層学習によるウメ「露茜」の熟度判断」(2018年9月23日、於:鹿児島大学群元キャンパス)を骨子とし、画像からの物体検出等について大幅に加筆・修正し作成した。

引用文献

- Adhikari, B., J. Peltomaki, J. Puura and H. Huttunen (2018) Faster Bounding Box Annotation for Object Detection in Indoor Scenes. In *2018 7th European Workshop on Visual Information Processing (EUVIP)* IEEE: 1-6.
- 浅川伸一 (2016) 深層学習をめぐる最近の熱狂, 基礎心理学研究, 35 (2): 149-162.
- Bargoti, S and J. Underwood (2017) Deep fruit detection in orchards. In 2017 IEEE International Conference on Robotics and Automation: 3626-3633.
- 藤吉弘亘, 山下隆義 (2017) 深層学習による画像認識, 日本ロボット学会誌, 35 (3): 180-185.
- 市川岳, 草田育美, 石井雅樹 (2017) 林檎の収穫適期判定を目的とした樹上果実の検出手法, 平成27年度日本知能情報ファジィ学会東北支部研究会 T1-3.
- 岸知彦, 加藤幸, 森奈緒子, 佐藤江里子, 土居良一, 溝口勝 (2010) 簡易モニタリングシステムによるリンゴ収穫適期の判断方法, H23 農業農村工学会大会講演会講演要旨集: 792-793.
- Krizhevsky, A., I. Sutskever and G. E. Hinton (2012) ImageNet Classification with Deep Convolutional Neural Networks, In Proc of the 25th International Conference on Neural Information Processing Systems, Vol. 1: 1097-1105.
- 草田育美, 石井雅樹, 山根治起 (2016) 屋外における果実収穫適期判定を目的とした画像補正手法に関する検討, 日本知能情報ファジィ学会第26回ソフトサイエンス・ワークショップ/平成27年度東北支部研究会講演論文集: 60-63.
- Liu, W., D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C. Y. Fu and A. C. Berg (2016) SSD: Single shot multibox detector. In European conference on computer vision: 21-37.

- 松尾豊 (2015) 人工知能の未来とデータ共有の新しい可能性, 情報管理, 58 (8): 597-605.
- 中山英樹 (2015) 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習, 信学技報, 115 (146): 55-59.
- 中山英樹 (2017) 画像解析関連コンペティションの潮流, 電子情報通信学会誌, 100 (5): 373-380.
- 小川秀夫, 酒井大輔 (2011) 画像処理によるキュウリの葉の病気診断, 愛知教育大学研究報告自然科学編, 58: 13-19.
- 大村和暉, 八幡壮, 小澤誠一, 大川剛直, 村上則幸, 辻博之 (2018) 大豆の生育情報を自動取得する画像センシング手法の開発: Single Shot MultiBox Detector の導入. In 人工知能学会全国大会論文集 2018 年度人工知能学会全国大会 (第 32 回) 論文集: 2G3-OS-10c-02
- Redmon, J., S. Divvala, R. Girshick and, A. Farhadi (2016) You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition: 779-788.
- Rykov, A. (2016) Port of Single Shot MultiBox Detector to Keras. 27. browsed on 5. 5. 2018.
- Simonyan, K and A. Zisserman (2014) Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv: 1409. 1556*.
- 建本聡 (2018) 深層学習を利用したブドウのデラウェアのジベレリンの適期判断について 農業環境工学関連学会 2018 年合同大会: GS20-5
- 梅田弘之 (2018) ビジネスに活用するための AI を学ぶ 連載 [第 8 回]: 機械学習の仕組みと学習データ <https://thinkit.co.jp/article/13201> 2019 年 2 月 15 日参照
- 和歌山県果樹試験場うめ研究所, 徳島県立農林水産総合技術支援センター, 宮崎県総合農業試験場 (2016) ウメ「露茜」の早期多収生産及び高品質果実供給技術 栽培管理マニュアル: p21.
- 八重垣英明, 山口正己, 土師岳, 末貞佑子, 三宅正則, 木原武士, 鈴木勝征, 内田誠 (2012) ウメ新品種「露茜」, 果樹研究所研究報告, (13): 1-6.
- Zhang, L., J. Jia, G. Gui, X. Hao, W. Gao and M. Wang (2018) Deep Learning Based Improved Classification System for Designing Tomato Harvesting Robot. IEEE Access, 6: 67940-67950.

受付日 2018 年 12 月 13 日
 受理日 2019 年 5 月 14 日
 担当部会 生命・生物学分野

深層学習を利用したウメ「露茜」の画像による熟度分類

Agricultural Information Research 28 (3) 2019. 108–114

Image-based Determination of Plum “Tsuyuakane” Ripeness via Deep Learning

Satoshi Tatamoto^{*1)}, Yoko Harada¹⁾ and Kenji Imai²⁾

1) *Agricultural and Horticultural Research Division, Tokushima Agriculture, Forestry and Fisheries
Technology Support Center, Ishii Ishii Ishii-cho, Myozai-gun, Tokushima, 779-3233 Japan*

2) *Resources and Environmental Research Division, Tokushima Agriculture, Forestry and Fisheries
Technology Support Center, Ishii Ishii Ishii-cho, Myozai-gun, Tokushima, 779-3233 Japan*

Abstract

We determined the ripeness of plums (“Tsuyuakane”) from images with combined object detection by using a single-shot multi-box detector (SSD) and a convolutional neural network (CNN). From June to July 2018 we obtained digital images and movies to characterize changes in the fruits on Tsuyuakane trees: 443 images were used to train the SSD in fruit recognition, and 5823 images were used to train the CNN for ripeness classification. The pictures were subsequently classified into five groups based on fruit ripeness, with the resulting classification accuracy at 94%. Subsequent training of the CNN with 366 images originally withheld from SSD training resulted in an increase of ripeness classification accuracy to 96%. These results suggest that this deep-learning method can be utilized to determine fruit ripeness based on training with sequential images depicting fruit growth.

Keywords

deep learning, ripeness classification, object detection, object recognition, plum

* Corresponding Author

E-mail: tatamoto_satoshi_1@pref.tokushima.jp