

SPECIAL BULLETIN  
OF THE  
KOCHI AGRICULTURAL RESEARCH CENTER  
No.21  
March 2026

高知県農業技術センター  
特別研究報告

第 21 号

令和 8 年 3 月

高知県農業技術センター  
高知県南国市廿枝1100

KOCHI AGRICULTURAL RESEARCH CENTER  
Hataeda 1100, Nankoku Kochi 783-0023, Japan



## 序 文

高知県において、ユズと土佐文旦は栽培面積および出荷量が全国第1位であり、中山間地域の基幹品目として位置付けられている。しかし、特にユズにおいては、生産現場で実施されている収穫前のお荷量予測の精度が低いことが問題となっていた。また、隔年結果性によって果実収量が不安定となりやすいことが課題であった。これらの課題を解決するために、スマート農業技術を活用して、省力的かつ高精度な出荷量予測技術の開発が求められていた。

そこで本研究では、カンキツ類のお荷量予測に必要な生理生態情報の「見える化」を目的として、土佐文旦およびユズにおける着花量の定量化技術、LAIの測定技術、着果量の推定方法ならびに果実階級比率の予測技術を検討し、それぞれの精度を検証した。

本報告は、これらの研究成果を取りまとめたものであるが、高知県大学院(博士課程後期)派遣研修事業において、高知工科大学大学院工学研究科教授の吉田真一博士のご指導を賜り、著者の学位論文として高知工科大学大学院工学研究科に提出されたものを、ここに高知県農業技術センター特別研究報告として公表するものである。これらの成果が関係機関に活用され、本県果樹産業の更なる生産拡大に活用されれば幸いである。

令和8年3月

高知県農業技術センター果樹試験場 場長

五百蔵 茂



デジタル技術を用いたカンキツ類の出荷量予測に関する  
生理生態情報の測定技術

谷本 佑

高知県農業技術センター 果樹試験場

Utilizing Digital Technologies to Measure Crop Physio-Ecological Information  
for Citrus Shipment Volume Prediction

Yuu Tanimoto

Kochi Agricultural Research Center Fruit Tree Experiment Station



# 目 次

|                                       |    |
|---------------------------------------|----|
| 第1章 緒 言                               | 1  |
| 1.1 本研究の背景                            | 1  |
| 1.2 本研究の目的                            | 3  |
| 1.3 本研究の構成および意義                       | 3  |
| 1.4 参考文献                              | 4  |
| 第2章 露地土佐文旦における着花量の簡易測定技術および葉面積指数の測定技術 | 7  |
| 2.1 はじめに                              | 7  |
| 2.2 材料および方法                           | 7  |
| 2.2.1 空撮画像の二値化処理による着花量の定量化方法の検討       | 7  |
| 2.2.2 PCA による LAI の測定方法の検討            | 8  |
| 2.2.3 花量, 収量および LAI の関係               | 9  |
| 2.3 結果                                | 10 |
| 2.3.1 空撮画像の二値化処理による着花量の定量化方法の検討       | 10 |
| 2.3.2 PCA による LAI の測定方法の検討            | 14 |
| 2.3.3 花量, 収量および LAI の関係               | 15 |
| 2.4 考察                                | 16 |
| 2.5 参考文献                              | 18 |
| 第3章 葉面積指数を用いたユズのせん定の定量化               | 19 |
| 3.1 はじめに                              | 19 |
| 3.2 材料および方法                           | 19 |
| 3.2.1 着果樹を用いた PCA による LAI 測定方法の検討     | 19 |
| 3.2.2 未着果樹を用いた PCA による LAI 測定方法の検証    | 20 |
| 3.2.3 PCA-LAI によるせん定量の指標化             | 20 |
| 3.3 結果                                | 21 |

|   |    |
|---|----|
| 3.3.1 着果樹を用いた PCA による LAI 測定方法の検討                 | 21 |
| 3.3.2 未着果樹を用いた PCA による LAI 測定方法の検証                | 22 |
| 3.3.3 PCA-LAI によるせん定量の指標化                         | 23 |
| 3.4 考察  | 24 |
| 3.5 参考文献  | 25 |
| <br>  |    |
| 第4章 ユズの着果数推定に用いる果実検出モデルの比較検討                      | 26 |
| 4.1 はじめに  | 26 |
| 4.2 材料および方法                                       | 26 |
| 4.2.1 UAV 画像の取得                                   | 26 |
| 4.2.2 データセットの構築                                   | 27 |
| 4.2.3 学習の実行環境                                     | 30 |
| 4.2.4 YOLOv8, YOLOv9 および YOLOv5u の概要              | 30 |
| 4.2.5 モデル学習の実行                                    | 30 |
| 4.2.6 評価指標  | 30 |
| 4.2.7 構築した学習モデルの評価                                | 31 |
| 4.3 結果および考察                                       | 31 |
| 4.3.1 データ拡張によりデータセットの画像数を離れた学習モデルの比較              | 31 |
| 4.3.2 園地毎のデータセットを用いた学習モデルの比較                      | 33 |
| 4.3.3 曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの比較 | 35 |
| 4.4 参考文献  | 37 |
| <br>  |    |
| 第5章 多項式回帰を用いたユズの果実階級比率予測モデルの構築                    | 38 |
| 5.1 はじめに  | 38 |
| 5.2 材料および方法                                       | 38 |
| 5.2.1 データセットの構築                                   | 38 |
| 5.2.2 果実階級比率予測モデルの構築                              | 39 |

|                              |    |
|------------------------------|----|
| 5.2.3 果実階級比率予測モデルの評価         | 39 |
| 5.2.4 果実階級比率予測モデルの検証         | 40 |
| 5.2.5 果実階級比率予測モデルに用いる樹数の検討   | 40 |
| 5.2.6 生産者園における果実階級比率予測モデルの検証 | 40 |
| 5.3 結果                       | 40 |
| 5.3.1 果実階級比率予測モデルの構築と評価      | 40 |
| 5.3.2 果実階級比率予測モデルの検証         | 44 |
| 5.3.3 果実階級比率予測モデルに用いる樹数の検証   | 45 |
| 5.3.4 生産者園における果実階級比率予測モデルの検証 | 46 |
| 5.4 考察                       | 48 |
| 5.5 参考文献                     | 49 |
| 第6章 結 言                      | 51 |
| 摘 要                          | 52 |
| Summary                      | 54 |

## 第 1 章 緒 言

### 1.1 本研究の背景

日本の農業は、2000 年から 2020 年の 20 年間で個人経営の経営体数および基幹的農業従事者数が大幅に減少しており、今後も農業従事者の高齢化および担い手数の減少により、農業経営体数の大幅な減少が見込まれている（農林水産省 2024）。世界的にみても、世界の農場数は 2020 年の 6 億 1600 万から 21 世紀末には 2 億 7200 万に減少することが予測されており（Mehrabi 2023）、サステナビリティ（持続可能性）の観点からも対応が急務である。このような情勢の中、農業の持続的な発展のためには、生産性の向上に資するスマート農業技術の更なる実用化が求められている（農林水産省 2025）。スマート農業とは、ロボット、AI (Artificial Intelligence)、IoT (Internet of Things) 等の先端技術を活用する農業のことで、例えば、ロボットトラクタ、リモコン草刈り機、水管理システムやハウスの環境制御システム等が挙げられる。スマート農業技術を利用することで、作業の自動化、情報共有の簡易化およびデータの効率的な利用が可能となり、現在、様々な部門で研究開発および普及実装が進んでいる。例えば高知県では、作物生産を決定づける光合成や成長等の生理生態情報を「見える化」し、生理生態情報に基づく合理的な営農支援情報として「使える化」を行い、それらの情報を産地で「共有化」する仕組みである IoP (Internet of Plants) の研究および実装が、施設園芸を中心に進められている（Next 次世代 Internet of Plants, <<http://kochi-iop.jp>>, 2025 年 2 月 15 日参照, 高知大学 IoP 共創センター, <<https://www.kochi-u.ac.jp/iopc3>>, 2025 年 2 月 15 日参照, Kitano et al. 2022）。しかし果樹栽培では、リモコン草刈り機や防除用ドローンといった一部のスマート農業機器は利用されているものの、施設園芸における IoP の実装のような急速な展開は見られない。これは、地域特性に応じて多種多様な果樹品目が栽培されており、データを効率的に活用するためには、品目毎の生理生態情報を「見える化」する技術の開発が必要となるためである。

果樹での「見える化」が可能な生理生態情報として、光合成、呼吸、蒸散や発芽、開花（着花）、生理落果の時期や量および結実量等が挙げられる。そのうち出荷量予測に関する生理生態情報は、生育診断のみならず、労務管理および販売戦略の策定においても極めて重要な情報である。カンキツ類は一般的に隔年結果性が強く（木原, 小中原 2000）、果実収量（=収入）が不安定となりやすい。また、事前に出荷数量と価格を決定し、その契約に基づいて実施される相対取引では、収穫前のお荷量予測が必要であるが、生産現場で実施されている予測方法は精度が低いことが問題となっている。出荷量の予測精度向

上は、農業経営体の収入が安定することにつながり、経営の安定化および規模拡大に至る好循環をもたらすと考えられる。したがって、これらの課題を解決するためには、出荷量に直接関係する着花量および着果量の推定方法や、生産性に関連する葉面積指数 (Leaf Area Index, 以下, LAI) の高精度かつ簡易な測定方法を開発する必要がある。

着花量は、着果量を早期に予測するために重要な情報である。着花量の定量化により、その情報に応じた肥培管理技術の開発が可能となり、労務管理においても、摘果や収穫に必要な人員の予測に役立つと考えられる。しかし、枝先 20 cm 調査法（カンキツの調査方法編集委員会 1987）等の既存のサンプリング手法を用いた着花数の計数は、極めて多大な労力が必要である。そこで近年は、画像処理技術を用いた花量の定量化に関する研究が進められている。特に深層学習 (Deep Learning) を用いた花の物体検出モデルの開発が、様々な樹種で報告されている。例えば Lin et al. (2022) は、物体検出アルゴリズムの YOLO (You Only Look Once) のバージョンの一つである YOLOv4 (Bochkovskiy et al. 2020) を用い、ライチ樹体の空撮画像から花房を検出するモデルを開発している。また松岡ら (2024) は、YOLOv5 (Jocher et al. 2020) および YOLOv8 (Jocher et al. 2023) を用い、ブルーベリー樹体の側面画像から正常な花芽を検出する方法を報告している。さらに Estrada et al. (2024) は、YOLOv5, YOLOv7 (Wang et al. 2022), YOLOv8 または multi-column deep neural network を使用した Density Map を用い、モモ樹体の側面画像から高密度の花数を計数する技術を開発している。これら手法は、他の品目への応用も可能だと考えられるが、例えば、高知県で最も産出金額の多い果樹である土佐文旦（農林水産省 2022, 図 1-1）は総状花序を形成し（片山, 仁藤 1993）、花序内で開花にバラツキが見られるため（仁藤ら 1993）、物体検出モデルの構築には非常に多様な学習用画像が必要となると予測される。また、総状花序は複数の花が密集しているため、空撮画像のような遠距離から撮影した画像では解像度が低くなり、花毎の検出および計数も困難だと考えられる。Dias et al. (2018) が報告する Semantic Segmentation を用いた花の検出方法の利用も考えられるが、一般的に Semantic Segmentation は物体検出と比較してアンテーションコストがかかり、モデルが複雑で、GPU メモリ使用量も高い等のデメリットがある。したがって、品種、品目の特性に応じた着花量評価手法の開発が必要である。

着果量は収量に直接的に影響するため、収穫時の労務管理や出荷計画の立案上、着花量以上に重要な情報である。カンキツ類の着果数を予測するためのサンプリング手法について、

例えばUnited States Department of Agriculture(1972)は、早生オレンジ、バレンシアオレンジおよびグレープフルーツの生育初期において1ブロック当たり2樹、1樹当たり主枝2本、1主枝当たり側枝2本のサンプリング調査を行うことで、園地内着果数を変動係数10%以内で予測できたと報告している。またStout(1962)は、テンプル、タンゼリンおよびタンゼロについて、1園当たり2樹、1樹当たり4カ所をフレームカウンティング法により調査することで1樹当たり平均着果数を14~32%の誤差で予測できたと報告している。これらのサンプリング手法の推定精度は高いものの、サンプリング自体に時間と労力を要するため、生産現場からはより省力的な手法が求められている。そのため着果量推定に関しても、深層学習を用いた果実の物体検出モデルの開発が進展している。カンキツ類の果実検出に関する最近の研究として、Zhang et al. (2022), Li et al. (2023), Gremes et al. (2023), Jing et al. (2024)およびAng et al. (2024)等の報告が挙げられる。近年はさらに、無人航空機(Unmanned Aerial Vehicle, 以下, UAV)により大量の画像を安価に短時間で取得することが可能となり、UAV画像と深層学習を組み合わせた果実検出に関する研究も多く報告されている。例えば、ネーブルオレンジ(Apolo-Apolo et al. 2020), ココナッツ(Novelero et al. 2022), ライチ(Xiong et al. 2023), リンゴ(Wang et al. 2023), クリ(Arakawa et al. 2023)等の研究が報告されている。深層学習を用いた物体検出モデルは近年急速に進展しており、今後も様々な樹種における果実検出モデルの開発が進むと考えられる。

一方で、どのような物体検出モデルにおいても良好な結果を得るためには、様々な条件で撮影した多くの学習データが必要である。しかし、実際に多量の画像を準備することは労力やコストの面から困難な場合がある。そこでデータ拡張(Data Augmentation)と呼ばれる、画像を変換、生成する手法が一般的に用いられる。データ拡張には、幾何学的変換(Geometric Transformation), 色空間(Color Space Transformation), ぼかし(Blurring), ノイズ付加(Noise Injection)等があり(Montserrat et al. 2017, Shorten et al. 2019), 画像の一部を別のパッチ画像で置き換えるCutMix(Yun et al. 2019)や、画像中のランダムな領域を消去するRandom Erasing(Zhong et al. 2020)と呼ばれる手法もある。敵対的生成ネットワーク(Generative Adversarial Network, 以下, GAN, Goodfellow et al. 2014)を使用して新しい画像を生成し、それを学習データに組み込むことも効果的である。さらに、条件付きGANの一種であるPix2pix(Isola et al. 2017)と呼ばれる、入力画像を対応する出力画像にマッピングすることで学習データを生成し、対応する出力画像にマッピングすることで、学習データを生成する手法も存在する。このように、様々なデータ拡張方法が

開発されているものの、データの多様性を増大させるためにはその組み合わせも重要であり、検出対象物に応じた適切な方法を選択する必要がある。

果実のサイズも、収量および収入に直接的に影響する重要な情報である。市場出荷の場合、多くの果樹は果実サイズ(階級)によって価格が決定されるため、収穫前の果実サイズの把握は販売戦略を決定する上で不可欠である。しかし、収穫前に果実サイズを予測する研究はあまり報告されていない。リンゴ(Gené-Mola et al. 2021, Lu et al. 2022), マンゴー(Neupane et al. 2022)および果菜類(Zheng et al. 2022)等で果実サイズを予測する手法が開発されているが、これらの手法は個々の果実サイズを推定する手法であり、園地および樹当たりの果実サイズを予測するためには、同時に効率的なサンプリング手法が求められる。リンゴ(Zhang et al. 1995)やキウイフルーツ(McAneney et al. 1989)では、サイズ予測に応用可能な果実重分布に関する研究が発表されているが、カンキツ類は果実直径に基づき出荷されることが多く、高知県が全国で最も栽培面積の多いユズ(農林水産省 2021, 図1-2)においても果実直径に基づいた階級が設定されるため、他の手法を検討する必要がある。果樹における果実サイズの予測に利用可能なサンプリング手法として、リンゴにおけるサイズ予測モデルで利用するために開発されたサンプリング手法(Marini et al. 2019a, Marini et al. 2019b, Marini et al. 2019c)や、リンゴ、ブドウおよびキウイフルーツの果樹園全体の果実数を推定するためのMultilevel Systematic Sampling(Wulfsohn et al. 2012)が開発されている。近年のマシンビジョン(Machine Vision)技術の進歩を考慮すると、その応用に適したサンプリング手法を開発し、さらに果実のサイズを予測するための効果的な手法を構築することがますます重要となっている。

LAIは、果樹における生産性を向上させる上で極めて重要な生理生態指標である。作物における収量の多少は、葉の物質生産の収支結果であり、一定面積以上の葉数または葉面積に依存している。そのため果樹においても、単位面積当たりの収量を最大とする最適LAIが存在すると考えられている(橘, 中井 1989)。生育期間中のLAIを把握することで、LAIに応じた肥培管理を行うことができる可能性がある。また、LAIの把握により、生産性(=出荷量)の予測にも活用できる可能性がある。LAIとは単位土地面積当たり存在する葉面積(片面)の総和( $\text{m}^2/\text{m}^2$ )であるが、果樹において実際のLAIを算出するには、樹体の総葉数に個葉面積を乗ずる必要があり、多大な時間と労力が必要で現実的ではない。そこで、プラントキャノピーアナライザー(Plant Canopy Analyzer, 以下, PCA)を用いたLAIの測定方法が開発されている。PCAは、魚眼レンズセンサーへの入射光を5つに角度分割し、入射光はフィルタにより490 nm

以上の放射光を遮蔽して検出器で測定する。測定したギャップフラクションは、放射伝達モデルを用いて LAI に換算する(メイワフォーシス株式会社, <<https://meiwanet.co.jp/products/lai-2200c/>>, 2025 年 2 月 15 日参照)。1 回の測定時間は 30 秒程度と極めて短い。露地ウンシュウミカンにおいては山本, 岩谷(2022)が LAI の測定方法を開発しているが, 土佐文旦およびユズの樹体はウンシュウミカンと比較して大きく, さらに土佐文旦の葉はウンシュウミカンと比較して大きい(森永 1993), 品目毎の測定方法を検討する必要がある。



図 1-1 土佐文旦(*Citrus maxima* (Burm.) Merr.)



図 1-2 ユズ(*Citrus junos* Sieb. ex Tanaka.

坂本晶子氏撮影)

## 1.2 本研究の目的

以上のように, 果樹における出荷量予測に関する生理生態情報の「見える化」に資する研究はこれまでも行われている。しかし, 高知県の特産カンキツ類である土佐文旦およびユズへの応用を考えた場合, 着花量の定量については, 土佐文旦の花の咲き方が他の果樹(特にカンキツ類)とは異なること, 着果量の推定については, ユズの果皮色が既存研究で用いられたオレンジ色の品種とは異なり黄色であること, 収穫前の果実階級比率の把握については, カンキツ類で園地および樹当たりの果実サイズを予測する手法が開発されていないこと, PCA による LAI の測定については, 土佐文旦およびユズの樹体特性が既存研究で用いられたウンシュウミカンとは異なることから, 既存研究とは異なる品種, 品目の特性に応じた手法の検討および開発が必要だと考えられる。

そこで本研究では, 4 つの技術開発を行うこととする。まず, 土佐文旦における着花量の簡易測定技術および LAI の測定技

術の開発, 次に, ユズにおける LAI の測定技術の開発および連年安定結実可能な LAI の解明, さらに, ユズにおける着果数推定に必要なデータ拡張手法の検討, そして最後に, ユズにおける収穫前に果実階級比率を予測するモデルの開発を行う。

## 1.3 本研究の構成および意義

図 1-3 に本研究の構成および意義を示す。

まず第 1 章では, 本研究の背景について述べる。農業の生産性向上に資するスマート農業技術の必要性和果樹におけるスマート農業技術の展開の課題について述べた後, 果樹, 特にカンキツ類の出荷量予測に必要な生理生態情報とこれまでの研究ならびに課題を述べる。その後, 本研究の目的, 構成および意義について述べる。

次に第 2 章では, 土佐文旦の着花量の簡易測定技術および LAI の測定技術を開発する。土佐文旦の開花期に空撮用 UAV を用いて樹体を撮影し, 撮影画像の二値化により着花量を定量化する。さらに, 植物の LAI を瞬時に測定可能である PCA の測定方法を決定し, これらの測定技術を用いて花量, 収量および LAI の関係を調査する。

第 3 章では, ユズにおける LAI を測定する技術を開発し, さらに, 連年安定結実可能な LAI を明らかにする。ユズにおける重要管理技術であるせん定の定量化指標として LAI に着目し, ユズにおける PCA の測定方法を決定する。高知県香美市および安芸市の生産者の園地におけるユズの LAI および収量の関係を調査し, 隔年結果性および収量性の観点から, 適正なせん定量を指標化する。

第 4 章では, 空撮用 UAV を用いて撮影したユズ樹体の空撮画像から着果数を推定する手法を確立するために, 学習条件を違えた 3 種類の YOLO モデルの果実検出性能を比較する。データ拡張によりデータセットの画像数を違えて学習させた果実検出モデルの予測精度を比較するとともに, 特定の園地および特定の天候の画像データセットにより学習させたモデルの予測精度を比較する。

第 5 章では, ユズにおいて収穫前に果実階級比率を予測するモデルを開発する。収穫時の平均果実横径と各階級の比率データの多項式回帰分析により, 最適な多項式の次数を検討し, モデルの信頼性を評価する。さらに, モデルの精度を保証するための調査樹数を検討し, 香美市の生産者の園地における予測モデルの精度を検証する。

最後に第 6 章では, 本研究の結論と総括を述べ, 残された課題と今後の展開について述べる。

本研究において開発した技術は, 多様な特性を持つカンキツ類における出荷量予測に関する生理生態情報を「見える化」することにつながる。これらの技術は, 生理生態情報に基づく

営農支援情報として「使える化」することで、スマート農業技術の実用化をさらに促進すると考えられる。

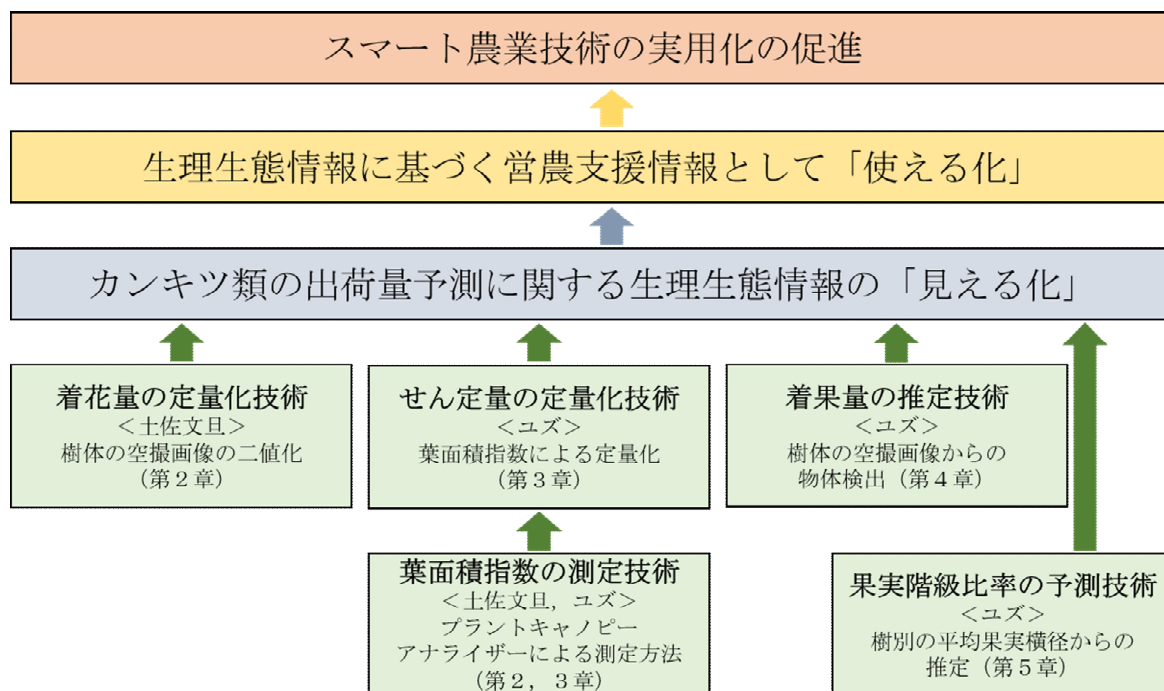


図1-3 本研究の構成および意義

#### 1.4 参考文献

- 1) Ang, G., T. Zhiwei, M. Wei, S. Yuepeng, R. Longlong, F. Yuliang, Q. Jianping and X. Lijia (2024) Fruits Hidden by Green: An Improved YOLOv8n for Detection of Young Citrus in Lush Citrus Trees, *Frontiers in Plant Science*, 15:1375118.
- 2) Apolo-Apolo, O. E., J. Martinez-Guanter, G. Egea, P. Raja and M. Pérez-Ruiz (2020) Deep Learning Techniques for Estimation of the Yield and Size of Citrus Fruits Using a UAV, *European Journal of Agronomy*, 115:126030.
- 3) Arakawa, T., T. S. T. Tanaka and S. Kamio (2024) Detection of On-Tree Chestnut Fruits Using Deep Learning and RGB Unmanned Aerial Vehicle Imagery for Estimation of Yield and Fruit Load, *Agronomy Journal*, 116(3):973-981.
- 4) Bochkovskiy, A., C. Y. Wang and H. Y. M. Liao (2020) YOLOv4: Optimal Speed and Accuracy of Object Detection, arXiv: 2004.10934v1 [cs.CV] 23 Apr 2020.
- 5) Dias, P. A., A. Tabb and H. Medeiros (2018) Multispecies Fruit Flower Detection Using a Refined Semantic Segmentation Network, *IEEE Robotics and Automation Letters*, 3(4):3003-3010.
- 6) Estrada, J. S., J. P. Vasconez, L. Fu and F. A. Cheein (2024) Deep Learning Based Flower Detection and Counting in Highly Populated Images: A Peach Grove Case Study, *Journal of Agriculture and Food Research*, 15: 100930.
- 7) Gené-Mola, J., R. Sanz-Cortiella, J. R. Rosell-Polo, A. Escolà and E. Gregorio (2021) In-Field Apple Size Estimation Using Photogrammetry-Derived 3D Point Clouds: Comparison of 4 Different Methods Considering Fruit Occlusions, *Computers and Electronics in Agriculture*, 188:106343.
- 8) Goodfellow, I., J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville and Y. Bengio (2014) Generative Adversarial Nets, In *Advances in Neural Information Processing Systems* 27, 2672-2680.
- 9) Gremes, M. F., I. R. Fermo, R. Krummenauer, F. C. Flores, C. M. G. Andrade and O. C. d. M. Lima (2023) System of Counting Green Oranges Directly from Trees Using Artificial Intelligence, *AgriEngineering*, 5(4):1813-1831.
- 10) Isola, P., J. Y. Zhu, T. Zhou and A. A. Efros (2017) Image-to-Image Translation with Conditional Adversarial Networks, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1125-1134.

- 11) Jing, J., M. Zhai, S. Dou, L. Wang, B. Lou, J. Yan and S. Yuan (2024) Optimizing the YOLOv7-Tiny Model with Multiple Strategies for Citrus Fruit Yield Estimation in Complex Scenarios, *Agriculture*, 14(2):303.
- 12) Jocher, G., A. Chaurasia and J. Qiu (2023) Ultralytics YOLOv8, <<https://github.com/ultralytics/ultralytics>>, 2025年2月15日参照.
- 13) Jocher, G., A. Stoken, J. Borovec, NanoCode012, ChristopherSTAN, L. Changyu, Laughing, tkianai, A. Hogan, lorenzomamma, yxNONG, AlexWang1900, L. Diaconu, Marc, wanghaoyang0106, ml5ah, Doug, F. Ingham, Frederik, Guilhen, Hatovix, J. Poznanski, J. Fang, L. Yu, changyu98, M. Wang, N. Gupta, O. Akhtar, PetrDvoracek and P. Rai (2020) ultralytics/yolov5:v3.1 - Bug Fixes and Performance Improvements, <<https://doi.org/10.5281/zenodo.4154370>>, 2025年2月15日参照.
- 14) カンキツの調査方法編集委員会 (1987) カンキツの調査方法, 農林水産省果樹試験場興津支場, 静岡, 3.
- 15) 片山幸良, 仁藤信昌 (1993) カンキツ類の花序形成, 佐賀大学農学部彙報, 75:55-66.
- 16) 木原武士, 小中原実 (2000) ウンシュウミカンにおける隔年結果の現状と対策, 果樹試験場報告, 34:111-136.
- 17) Kitano, M., K. Nomura, T. Yamazaki, T. Iwao, M. Saitou, M. Mori, D. Yasutake, T. Kaneko, H. Ukeda, S. Ishizuka, T. Fujiwara and T. Okabayashi (2022) Internet of Plants (IoP) Empowers Bottom-up Innovations in Greenhouse Horticulture, *Environmental Control in Biology*, 60(1):3-12.
- 18) Li, Y., Z. Gong, Y. Zhou, Y. He and R. Huang (2023) Production Evaluation of Citrus Fruits Based on the YOLOv5 Compressed by Knowledge Distillation, In 2023 26th International Conference on Computer Supported Cooperative Work in Design (CSCWD), Rio de Janeiro, Brazil, 1938-1943.
- 19) Lin, P., D. Li, Y. Jia, Y. Chen, G. Huang, H. Elkhouchlaa, Z. Yao, Z. Zhou, H. Zhou, J. Li and H. Lu (2022) A Novel Approach for Estimating the Flowering Rate of Litchi Based on Deep Learning and UAV Images, *Frontiers in Plant Science*, 13:966639.
- 20) Lu, S., W. Chen, X. Zhang and M. Karkee (2022) Canopy-Attention-YOLOv4-Based Immature / Mature Apple Fruit Detection on Dense-Foliage Tree Architectures for Early Crop Load Estimation, *Computers and Electronics in Agriculture*, 193:106696.
- 21) Marini, R. P., J. R. Schupp, T. A. Baugher and R. Crassweller (2019a) Relationships between Fruit Weight and Diameter at 60 Days after Bloom and at Harvest for Three Apple Cultivars, *HortScience*, 54(1):86-91.
- 22) Marini, R. P., J. R. Schupp, T. A. Baugher and R. Crassweller (2019b) Sampling Apple Trees to Accurately Estimate Mean Fruit Weight and Fruit Size Distribution, *HortScience*, 54(6):1017-1022.
- 23) Marini, R. P., J. R. Schupp, T. A. Baugher and R. Crassweller (2019c) Estimating Apple Fruit Size Distribution from Early-Season Fruit Diameter Measurements, *HortScience*, 54(11):1947-1954.
- 24) 松岡和輝, 高杉翔, 岡本博史 (2024) 物体検出AIを用いたブルーベリーの花芽および果実の検出による圃場モニタリングの自動化に関する研究, *農業情報研究*, 33(1):27-43.
- 25) McAneney, K. J., A. C. Richardson and A. E. Green (1989) Kiwifruit Fruit Size Distributions. *New Zealand Journal of Crop and Horticultural Science*, 17(3):297-299.
- 26) Mehrabi, Z. (2023) Likely Decline in the Number of Farms Globally by the Middle of the Century, *Nature Sustainability*, 6:949-954.
- 27) Montserrat, D. M., Q. Lin, J. Allebach and E. J. Delp (2017) Training Object Detection and Recognition CNN Models Using Data Augmentation, *Electronic Imaging*, 29(10):27-36.
- 28) 森永邦久 (1993) カンキツの光合成の向上と果実生産に関する研究, 四国農業試験場報告, 53:135-205.
- 29) Neupane, C., A. Koirala and K. B. Walsh (2022) In-Orchard Sizing of Mango Fruit: 1. Comparison of Machine Vision Based Methods for On-the-Go Estimation, *Horticulturae*, 8(12):1223.
- 30) 仁藤伸昌, M. M. Rahman, 片山幸良 (1993) カンキツの総状花序における開花順序と結実性, *園芸学会雑誌*, 62(2):277-284.
- 31) 農林水産省 (2021) 令和3年産特産果樹動態等調査, <<https://www.e-stat.go.jp/stat-search/files?page=1&layout=datalist&toukei=00500503&tstat=000001020907&cycle=7&year=20210&month=0&tclass1=000001032892&tclass2=000001213907>>, 2025年2月15日参照.
- 32) 農林水産省 (2022) 令和4年産農業所得統計, <<https://www.e-stat.go.jp/stat-search/files?page=1&layout=datalist&toukei=00500206&tstat=000001015617&cycle=7&y>

- ear=20220&month=0&tclass1=000001019794&tclass2=000001215200>, 2025年2月15日参照。
- 33) 農林水産省 (2024) 農業経営をめぐる情勢について(令和6年4月), <[https://www.maff.go.jp/j/kobetu\\_ninait/e/nougyoukeiei\\_jousei\\_r6apr\\_set.pdf](https://www.maff.go.jp/j/kobetu_ninait/e/nougyoukeiei_jousei_r6apr_set.pdf)>, 2025年2月15日参照。
- 34) 農林水産省 (2025) スマート農業をめぐる情勢について(2025年2月), <<https://www.maff.go.jp/j/kanbo/smart/attach/pdf/index-254.pdf>>, 2025年2月15日参照。
- 35) Novelero, J.M. and J.C.D.Cruz (2022) On-Tree Mature Coconut Fruit Detection Based on Deep Learning Using UAV Images, In 2022 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom), Malang, Indonesia, 494-499.
- 36) Shorten, C. and T.M.Khoshgoftaar (2019) A Survey on Image Data Augmentation for Deep Learning, *Journal of Big Data*, 6(60):1-48.
- 37) Stout, R.G. (1962) Estimating Citrus Production by Use of Frame Count Survey, *Journal of Farm Economics*, 44(4):1037-1049.
- 38) 橋温, 中井滋郎 (1989) 異なった栽植密度におけるワセウンシュウの樹冠密度と収量及び葉面積指数との関係, *園芸学会雑誌*, 58(1):91-96.
- 39) United States Department of Agriculture (1972) Evaluation of Procedures for Estimating Citrus Fruit Yield, <[https://www.nass.usda.gov/Education\\_and\\_Outreach/Reports,\\_Presentations\\_and\\_Conferences/Yield\\_Reports/Evaluation%20of%20Procedures%20for%20Estimating%20Citrus%20Fruit%20Yield.pdf](https://www.nass.usda.gov/Education_and_Outreach/Reports,_Presentations_and_Conferences/Yield_Reports/Evaluation%20of%20Procedures%20for%20Estimating%20Citrus%20Fruit%20Yield.pdf)>, 2025年2月15日参照。
- 40) Wang, C. Y., A. Bochkovskiy and H. Y. M. Liao (2022) YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors, arXiv:2207.02696v1 [cs.CV] 6 Jul 2022.
- 41) Wang, H., J. Feng and H. Yin (2023) Improved Method for Apple Fruit Target Detection Based on YOLOv5s, *Agriculture*, 13(11):2167.
- 42) Wulfsohn, D., F.A. Zamora, C.P. Téllez, I. Z. Lagos and M. Garcia-Finana (2012) Multilevel Systematic Sampling to Estimate Total Fruit Number for Yield Forecasts, *Precision Agriculture*, 13:256-275.
- 43) Xiong, Z., L. Wang, Y. Zhao and Y. Lan (2023) Precision Detection of Dense Litchi Fruit in UAV Images Based on Improved YOLOv5 Model, *Remote Sensing*, 15(16):4017.
- 44) 山本晴彦, 岩谷潔 (2022) デジタルカメラを利用したカンキツ樹の総葉面積の計測, *農業技術大系果樹編 第1-I巻*, 農山漁村文化協会, 東京, 技22の20-技22の22.
- 45) Yun, S., D. Han, S. J. Oh, S. Chun, J. Choe and Y. Yoo (2019) Cutmix: Regularization Strategy to Train Strong Classifiers with Localizable Features, In Proceedings of the IEEE / CVF International Conference on Computer Vision (ICCV), 6023-6032.
- 46) Zhang, J., G.F. Thiele and R.N. Rowe (1995) Gala Apple Fruit Size Distribution, *New Zealand Journal of Crop and Horticultural Science*, 23(1):85-88.
- 47) Zhang, W., J. Wang, Y. Liu, K. Chen, H. Li, Y. Duan, W. Wu, Y. Shi and W. Guo (2022) Deep-Learning-Based in-Field Citrus Fruit Detection and Tracking, *Horticulture Research*, 9:uhac003.
- 48) Zheng, B., G. Sun, Z. Meng and R. Nan (2022) Vegetable Size Measurement Based on Stereo Camera and Keypoints Detection, *Sensors*, 22(4):1617.
- 49) Zhong, Z., L. Zheng, G. Kang, S. Li and Y. Yang (2020) Random Erasing Data Augmentation, In Proceedings of the AAAI Conference on Artificial Intelligence, 34(7), 13001-13008.

## 第 2 章 露地土佐文旦における着花量の簡易測定技術および葉面積指数の測定技術

### 2.1 はじめに

本章では、高知県で最も産出金額の多い果樹である露地土佐文旦(農林水産省 2022)に焦点を当て、空撮画像による着花量の定量化方法を開発し、さらに PCA による LAI の測定方法を検討した。また、花量、収量および LAI の関係から測定技術の実用性を評価した。

### 2.2 材料および方法

#### 2.2.1 空撮画像の二値化処理による着花量の定量化方法の検討


Treder et al. (2021) はナシにおいて、二値化処理をした画像中の花卉面積から実際の花房数を予測する手法を提案している。しかし、これは枝毎に同じ背景および同じ距離で撮影した画像を用いる手法であるため、背景の異なる野外で撮影した画像では実用困難である。さらに、空撮画像は一度に大量の画像データが入手可能だが、機体性能や撮影する樹体の樹高の違いから、厳密な撮影距離の調整が難しい。一方、土佐文旦を含むカンキツ類の花は品種固有の大きさを持ち、花間での変動は小さいため、Treder et al. (2021) の報告と同様に、花面積から花数が予測できる可能性が高い。そこで、背景や撮影距離に影響されない着花量の定量化指標として、空撮画像中の樹冠投影面積に占める花の面積の割合を推定花量と定義した。

高知県農業技術センター果樹試験場内露地ほ場(高知県高知市朝倉丁、以下、場内)に植栽間隔 4.0×4.0 m で植えられた、33 年生(2021 年時) 11 樹および 26 年生(2022 年時) 26 樹の開心自然形カラタチ土佐文旦を供試した。樹体の撮影は、2021 年 4 月 27 日(開花 1 分)、5 月 4 日(開花 4~6 分)、7 日(満開(開花 8 分)~落弁 1 分)、2022 年 5 月 1 日(満開)、6 日(開花終期(落弁 5 分))および 2023 年 4 月 26 日(開花 1 分)、29 日(開花 2 分)、5 月 4 日(開花 6~7 分)、5 日(満開)のいずれも曇天日の 6:30~17:00 の無風時に行った。開花割合は園地全体を達観で調査し判断した。


空撮用 UAV の Mavic mini (DJI 製) を用いて地上高 7.5~9.0 m から、撮影地表面が横 13.3~15.9 m、縦 10.0~11.9 m の範囲で、樹体に対して鉛直方向に 1 枚毎に ISO 感度がオート(100~1600)、シャッター速度が 4~1/8000 秒の設定で撮影した。なお、Mavic mini の機体サイズは 245×289×55 mm(長さ×幅×高さ、<<https://www.dji.com/jp/support/product/mavicmini>>、2025 年 2 月 15 日参照) と小型であり、樹冠上部から機体まで 5 m 以上離れていたため、撮影への UAV によるダウンウォッシュの影響はほとんどなかった。また、撮影高度は地上高 7.5~9.0 m とやや変動があるが、これは園地の傾斜や樹高に合わ

せ手動調整したため、かつ推定花量を画像中の樹冠投影面積に占める花の面積の割合で定義したため、影響は小さいと判断した。

画像データはサイズ 4000×2250 pixel、解像度 72 dpi、JPEG ファイル形式で保存した。撮影日毎に 10 または 12 枚(10 または 12 樹)の画像を無作為に選び、画像処理ソフトの GIMP 2.10.34(<<http://www.gimp.org>>、2025 年 2 月 15 日参照、以下、GIMP)を用いて、撮影画像 1 枚毎に樹体中心部から 1200×1200 pixel の範囲で切り出した(以下、1200 pixel 画像、図 2-1-a)。1200 pixel 画像を縦 8 分割×横 8 分割の 64 分割した後(以下、150 pixel 画像、図 2-1-b)、150 pixel 画像を 1200 pixel 画像 1 枚毎に無作為に各 10 枚(撮影日毎に合計各 100 または 120 枚)選んだ。抽出した 150 pixel 画像は、画像処理ソフトの Fiji-ImageJ(<<https://fiji.sc>>、2025 年 2 月 15 日参照)を用いて、NTSC 加重平均法(式(2-1))による 8-bit グレースケール画像への変換後の二値化(以下、RGB 画像の二値化)、または Red, Green, Blue, Hue, Saturation, Brightness の各 Channel 画像の二値化を実施した。二値化により白色となった部分を花と仮定し、推定花量(%)を式(2-2)で算出した。あわせて、実際の花の面積については、GIMP より同じ 150 pixel 画像の花の部分を手動で白く塗りつぶし、実測花量(%)を式(2-3)で算出し、推定花量と実測花量を比較した。ここでの樹冠投影面積は、150 pixel 画像全体である。RGB 画像の二値化方法について、Otsu の二値化法(Otsu 1979)および RenyiEntropy の二値化法(Kapur et al. 1985)による自動二値化アルゴリズムを使用する方法か、二値化閾値の最小値を 0 に固定し、最大値を手動で設定する方法で算出した推定花量を比較した。また、各 Channel 画像の二値化についても、Red, Green, Blue および Brightness Channel は二値化閾値の最小値を 0 に固定し、最大値を手動で設定する方法で、Hue および Saturation Channel は最大値を 255 に固定し、最小値を手動で設定する方法で算出した推定花量を比較した。なお、事前に画像の前処理方法を検討したが、結果に与える影響は小さかったため、本章では前処理を実施しなかった。推定花量を説明変数、実測花量を目的変数とした回帰分析(直線回帰)を行い、分散分析、自由度修正済み決定係数(以下、 $R^2$ )および式(2-4)で求めた赤池情報量基準(Akaike's Information Criterion、以下、AIC、Akaike 1998)で評価し、二値化方法を決定した。回帰分析における分散分析では、説明変数がどれほど目的変数を予測できるか検定する。また、 $R^2$  はモデルの適合度を評価する指標であり、AIC は異なるモデルの予測性能の比較のために使われる。分散分析の実施および  $R^2$  の算出には、エクセル統計 4.07(社会情報サービス製)を用いた。



(a) 1200 pixel 画像



(b) 150 pixel 画像

図 2-1 開花期の空撮画像における切り出し処理

$$Y = 0.298912 \times R + 0.586611 \times G + 0.114478 \times B \quad (2-1)$$

ここでYは輝度値,Rは赤色値,Gは緑色値,Bは青色値であり,それぞれ8-bit(0~255の範囲)の値を示す.

$$\text{推定花量 (\%)} = \frac{\text{二値化処理による画像中の白色面積}}{\text{画像中の樹冠投影面積}} \times 100 \quad (2-2)$$

$$\text{実測花量 (\%)} = \frac{\text{画像中の実際の花の面積}}{\text{画像中の樹冠投影面積}} \times 100 \quad (2-3)$$

$$\text{AIC} = n \left( \log \left( 2n \frac{\text{Se}}{n} \right) + 1 \right) + 2(p + 2) \quad (2-4)$$

ここでnはデータ数,Seは残差平方和,pは説明変数の数を示す.

### 2.2.2 PCAによるLAIの測定方法の検討

最初に,PCAを用いてせん定前後のLAIを測定し,実際のLAIに換算する補正式を検討した.なお,せん定時以外に葉の減少はないものとした。「2.2.1 空撮画像の二値化処理による着花量の定量化方法の検討」と同じ園地の26年生(2022年時)26樹のうち10樹を用い,実際のLAI(以下,実際LAI)を式(2-5)で求めた.全葉数は,2021年3月9~11日,2022年3月4~10日および2023年3月2~7日にカウンターを用いて計測した.個葉面積は,2021年3月2日(20枚/樹)および2022年3月14日(12枚/樹)に中庸な葉をサンプリングしてスキャナーのGT-X830(EPSON製)でスキャンした後,フリーソフトウェアのLIA for Win32(<<https://www.agr.nagoyau.ac.jp/~shinkan/LIA32>>,2025年2月15日時点で使用不可)で計測し,平均値を算出した.樹冠面積は,せん定前の2021年2月25日,2022年2月9日および2023年2月21日,せん定後の2021年3月10日,2022

年3月11日および2023年3月9日に,箱尺で樹幅(長径幅,短径幅)と樹高を測定し,樹冠を楕円と近似させて式(2-6)で算出した.PCA(LAI-2200C,LI-COR製)を用いて測定したLAI(以下,PCA-LAI)は,せん定前の2021年2月25日,2022年3月1日および2023年2月21日,せん定後の2021年3月9日,2022年3月11日および2023年3月9日に,山本,岩谷(2022)の方法に準じて90°のビューキャップを装着したPCAを用い,主幹表面から60cmの東西南北の4方位の位置より樹体中心に向かって測定した.付属の解析ソフトFV2200(LI-COR製)を用いて光路長をHorizontal(default)とし,天頂角を5つ(7,23,38,53,68°,以下,5天頂角),4つ(7,23,38,53°,以下,4天頂角),3つ(7,23,38°,以下,3天頂角)および2つ(7,23°,以下,2天頂角)としてPCA-LAIを算出し比較した.各天頂角で算出したPCA-LAIを説明変数,実際LAIを目的変数とした回帰分析(直線回帰)について,分散分析, $R^2$ およびAICで評価した.

$$\text{実際LAI} = \frac{\text{全葉数} \times \text{個葉面積}(\text{m}^2)}{\text{樹冠面積}(\text{m}^2)} \quad (2-5)$$

$$\text{樹冠面積}(\text{m}^2) = \frac{\text{樹幅長径幅}(\text{m})}{2} \times \frac{\text{樹幅短径幅}(\text{m})}{2} \times \pi \quad (2-6)$$

次に、構築した補正式を、測定方法を検討した園地とは異なる園地で評価した。20～25年生(2024年時)の開心自然形カラタチ台土佐文旦10樹を用い、せん定前後の実際LAIを求めた。全葉数は2024年3月7日に、樹冠面積はせん定前後の2024年2月20日および3月8日に測定し算出した。PCA-LAIは2024年2月23日および2月29日に前述の方法で測定し、5天頂角、4天頂角、3天頂角および2天頂角で算出した。天頂角毎のPCA-LAIを、構築した回帰式に入力して補正し(以下、補正LAI)、実際LAIと比較した。

### 2.2.3 花量、収量およびLAIの関係

調査は、「2.2.1 空撮画像の二値化処理による着花量の定量化方法の検討」と同じ園地の26年生(2022年時)26樹および「2.2.2 PCAによるLAIの測定方法の検討」と同じ園地の20～25年生(2024年時)21樹を用いた。PCAによるLAIの測定について、せん定前のLAIは2022年3月1日、2023年2月21日および2024年2月23日に、せん定後のLAIは2022年3月11日、2023年3月9日および2024年2月29日に、90°のビューキャップを装着したPCAを用い、主幹表面から60cmの東西南北の4方位の位置より樹体中心に向かって測定した。FV2200を用いて光路長をHorizontal、3天頂角としてPCA-LAIを算出した。「2.3.2 PCAによるLAIの測定方法の検討」で決定した補正式により、せん定前後の補正LAI(以下、せん定前LAIおよびせ

ん定後LAI)を算出した。

推定花量に用いた画像データについて、2022年5月1日(満開)、2023年5月5日(満開)および2024年5月1日(開花5分)のいずれも曇天日の8:30～17:00の無風時にMavic miniを用いて地上高7.5～9mから、撮影地表面範囲が横13.3～15.9m、縦10.0～11.9mで、樹体に対して鉛直方向に1枚毎に撮影し、サイズ4000×2250 pixel、解像度72 dpi、JPEGファイル形式で保存した。推定花量の算出は、Fiji-ImageJを用いて画像中の樹体部分を手動でポリゴン化し、その内部をNTSC加重平均法により8-bit グレースケール画像に変換した。閾値を最小値0、最大値195に手動設定して二値化した後(図2-2)、二値化により白色となった部分を花と仮定して推定花量(%)を算出した。さらに、「2.3.1 空撮画像の二値化処理による着花量の定量化方法の検討」の結果に基づき、推定花量を構築した回帰式に入力して補正した(以下、補正推定花量)。

2021年12月13日、2022年12月13日および2023年12月12日に収穫した果実の総重量(kg)を樹毎に調査した後、各樹の樹冠容積(m<sup>3</sup>)を半楕円体に近似させて式(2-7)で算出し、収量(kg/m<sup>3</sup>)を求めた。なお、カンキツ類の樹冠容積の算出には一般的に、7かけ法(カンキツの調査方法編集委員会 1987)を用いるが、本章では「2.2.2 PCAによるLAIの測定方法の検討」において、樹冠面積を楕円に近似させる必要があったため、本章では樹冠容積を半楕円体として算出した。

$$\text{樹冠容積}(\text{m}^3) = \frac{4}{3} \times \frac{\text{樹幅長径幅}(\text{m})}{2} \times \frac{\text{樹幅短径幅}(\text{m})}{2} \times \text{樹高}(\text{m}) \times \pi \times \frac{1}{2} \quad (2-7)$$

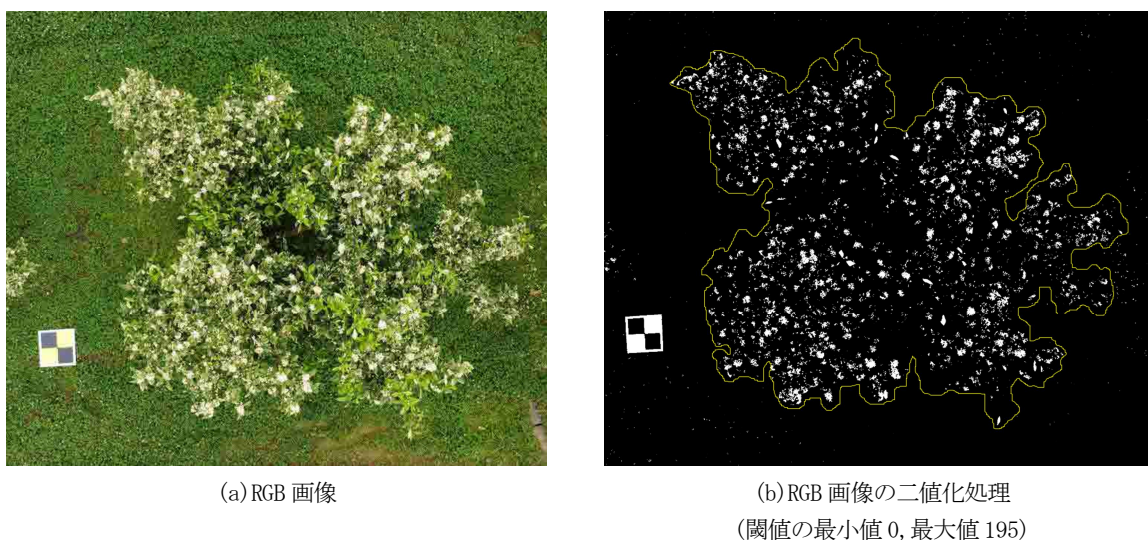


図 2-2 開花期の空撮画像の二値化処理


## 2.3 結果

### 2.3.1 空撮画像の二値化処理による着花量の定量化方法の検討

図 2-3 に代表的な 150 pixel 画像における各二値化処理画像を示す。Otsu の二値化法および RenyiEntropy の二値化法による自動二値化アルゴリズムでは、花のみならず葉も白色となり誤認識が多い傾向だったのに対し、二値化閾値を手動設定した場合は、葉が白くなる部分が少なく誤認識が少ない傾向だった。表 2-1 に推定花量と実測花量の直線回帰式の適合性の評価を示す。分散分析の結果、RenyiEntropy の二値化法を除く回帰式で  $p$  値が 0.001 未満であり、有意水準 1% 以下で有意であった。 $R^2$  について、Otsu の二値化法および RenyiEntropy の二値化法による自動二値化アルゴリズムではそれぞれ 0.04 および 0.00 と極めて低かった。一方で手動設定の場合、RGB 画像の  $R^2$  は、二値化閾値の最大値 180 の時に 0.74、210 の時に 0.85、Red Channel 画像の  $R^2$  は、二値化閾値の最大値 210 の時に 0.78、220 の時に 0.91、Blue Channel 画像の  $R^2$  は、二値化閾値の最大値 150 の時に 0.86、160 の時に 0.87 と、いずれも閾値の最大値が大きくなるにつれて  $R^2$  が高くなった。また、Saturation Channel 画像の  $R^2$  は、二値化閾値の最小値 70 の時に 0.75、60 の時に 0.77 と、閾値の最小値が小さくなるにつれて  $R^2$  が高くなった。AIC について、Otsu の二値化法および RenyiEntropy の二値化法による自動二値化アルゴリズムではそれぞれ 5592.01 および 5627.96 と高かった。一方で手動設定の場合、RGB 画像の AIC は、二値化閾値の最大値 180 の時に

4292.36、210 の時に 3754.44、Red Channel 画像の AIC は、二値化閾値の最大値 210 の時に 4159.73、220 の時に 3857.99、Blue Channel 画像の AIC は、二値化閾値の最大値が 150 の時に 3726.82、160 の時に 3651.98 と、閾値の最大値が大きくなるにつれて AIC が低くなった。また、Saturation Channel 画像の AIC は、二値化閾値の最小値が 70 の時に 4259.05、60 の時に 4180.10 と、閾値の最小値が小さくなるにつれて AIC が低くなった。

表 2-2 に、RGB 画像の二値化閾値の最大値を 195 とした場合の撮影時期別の直線回帰式の適合性の評価を示す。 $R^2$  について、開花 1 分では 2021 年 4 月 27 日および 2023 年 4 月 26 日で 0.47 および 0.56 と他の撮影時期と比較して低く、その他の調査日では 0.84~0.90 と高かった。AIC について、349.88~439.69 と開花状況による一定の傾向は見られなかった。また、回帰式の傾きは 0.72~1.30 と、開花が進むほど値が高くなる傾向が見られたが、開花状況による一定の傾向は見られなかった。表 2-3 に、Blue Channel 画像の二値化閾値の最大値を 155 とした場合の撮影時期別の直線回帰式の適合性の評価を示す。 $R^2$  について、開花 1 分では 2021 年 4 月 27 日および 2023 年 4 月 26 日で 0.62 および 0.53 と他の撮影時期と比較して低く、その他の調査日では 0.88~0.93 と高かった。AIC について、295.73~448.05 と開花状況による一定の傾向は見られなかった。また、回帰式の傾きは 0.78~1.18 と、開花が進むほど値が高くなる傾向が見られたが、開花状況による一定の傾向は見られなかった。



| RGB 画像 | 手動で花を<br>塗りつぶし | RGB 画像<br>閾値設定<br>最小値 0,<br>最大値 195 | Blue Channel<br>画像<br>閾値設定<br>最小値 0,<br>最大値 155 | Saturation<br>Channel<br>画像<br>閾値設定<br>最小値 65,<br>最大値 255 | 自動二値化<br>アルゴリズム<br>Otsu | 自動二値化<br>アルゴリズム<br>RenyiEntropy |
|--------|----------------|-------------------------------------|---|---|-------------------------|---------------------------------|
|--------|----------------|-------------------------------------|---|---|-------------------------|---------------------------------|

図2-3 代表的な 150 pixel 画像における各二値化処理画像

表 2-1 推定花量と実測花量の直線回帰式( $Y=aX + b$ )の適合性の評価

| 花量                    | 二値化の方法       | 推定花量の<br>閾値の最大値<br>(最小値) | データ数 | 平均値   | 傾き (a) | 切片 (b) |      |
|-----------------------|--------------|--------------------------|------|-------|--------|--------|------|
| 実測花量                  | —            | —                        | 980  | 3.50  | —      | —      |      |
|                       | Otsu         | —                        |      | 46.59 | -0.10  | 7.97   |      |
|                       | RenyiEntropy | —                        |      | 31.73 | -0.001 | 3.52   |      |
|                       | RGB 手動       | 180                      |      | 5.82  | 0.69   | -0.50  |      |
|                       |              | 190                      |      | 4.10  | 0.87   | -0.07  |      |
|                       |              | 195                      |      | 3.49  | 0.97   | 0.10   |      |
|                       |              | 200                      |      | 3.00  | 1.08   | 0.24   |      |
|                       |              | 210                      |      | 2.26  | 1.32   | 0.50   |      |
|                       | 推定花量         | Red Channel 手動           |      | 210   | 3.76   | 0.86   | 0.27 |
|                       |              |                          |      | 215   | 3.17   | 0.98   | 0.38 |
| Green Channel 手動      |              | 220                      | 2.69 | 1.12  | 0.49   |        |      |
|                       |              | 230                      | 3.44 | 0.34  | 2.33   |        |      |
| Blue Channel 手動       |              | 150                      | 3.76 | 0.89  | 0.15   |        |      |
|                       |              | 155                      | 3.41 | 0.96  | 0.22   |        |      |
|                       |              | 160                      | 3.10 | 1.03  | 0.30   |        |      |
| Hue Channel 手動        |              | 40                       | 3.40 | 0.33  | 2.36   |        |      |
|                       |              | 60                       | 2.99 | 0.96  | 0.62   |        |      |
|                       |              | 65                       | 3.42 | 0.86  | 0.55   |        |      |
| Saturation Channel 手動 | 70           | 3.92                     | 0.78 | 0.46  |        |        |      |
|                       | 230          | 3.40                     | 1.00 | 0.09  |        |        |      |

| 花量                    | 二値化の方法                | F値             | p値      | R <sup>2</sup> | AIC     |         |
|-----------------------|-----------------------|----------------|---------|----------------|---------|---------|
| 実測花量                  | —                     | —              | —       | —              | —       |         |
|                       | Otsu                  | 0036.57        | < 0.001 | 0.04           | 5592.01 |         |
|                       | RenyiEntropy          | 0000.02        | 0.90    | 0.00           | 5627.96 |         |
|                       | RGB 手動                | 2843.45        | < 0.001 | 0.74           | 4292.36 |         |
|                       |                       | 4228.42        | < 0.001 | 0.81           | 3989.28 |         |
|                       |                       | 4918.67        | < 0.001 | 0.83           | 3867.28 |         |
|                       |                       | 5487.71        | < 0.001 | 0.85           | 3777.00 |         |
|                       |                       | 5638.24        | < 0.001 | 0.85           | 3754.44 |         |
|                       | 推定花量                  | Red Channel 手動 | 3387.31 | < 0.001        | 0.78    | 4159.73 |
|                       |                       |                | 4223.56 | < 0.001        | 0.81    | 3987.97 |
| Green Channel 手動      |                       | 4961.28        | < 0.001 | 0.91           | 3857.99 |         |
|                       |                       | 218.18         | < 0.001 | 0.18           | 5428.40 |         |
| Blue Channel 手動       |                       | 5811.90        | < 0.001 | 0.86           | 3726.82 |         |
|                       |                       | 6148.38        | < 0.001 | 0.86           | 3679.43 |         |
|                       |                       | 6350.75        | < 0.001 | 0.87           | 3651.98 |         |
| Hue Channel 手動        |                       | 268.92         | < 0.001 | 0.21           | 5387.69 |         |
|                       |                       | 3297.55        | < 0.001 | 0.77           | 4180.10 |         |
|                       |                       | 3109.15        | < 0.001 | 0.76           | 4224.26 |         |
| Saturation Channel 手動 | 2966.61               | < 0.001        | 0.75    | 4259.05        |         |         |
|                       | Brightness Channel 手動 | 1528.24        | < 0.001 | 0.61           | 4703.54 |         |

表 2-2 RGB 画像の二値化閾値の最大値を 195 とした場合の撮影時期別の直線回帰式( $Y=aX + b$ )の適合性の評価

| 撮影年月日          | 開花状況                       | データ数 | 傾き(a) | 切片(b) | F値      | p値      | R <sup>2</sup> | AIC    |
|----------------|----------------------------|------|-------|-------|---------|---------|----------------|--------|
| 2021年<br>4月27日 | 開花1分                       | 100  | 0.72  | -0.12 | 90.04   | < 0.001 | 0.47           | 392.98 |
| 2021年<br>5月4日  | 開花4~6分                     | 100  | 1.09  | 0.27  | 673.09  | < 0.001 | 0.87           | 349.88 |
| 2021年<br>5月7日  | 満開 <sup>z)</sup> ~<br>落弁1分 | 100  | 1.07  | -0.12 | 512.43  | < 0.001 | 0.84           | 389.08 |
| 2022年<br>5月1日  | 満開                         | 100  | 0.80  | 0.29  | 860.94  | < 0.001 | 0.90           | 378.54 |
| 2022年<br>5月6日  | 開花終期 <sup>y)</sup>         | 100  | 1.04  | 0.18  | 696.28  | < 0.001 | 0.88           | 423.02 |
| 2023年<br>4月26日 | 開花1分                       | 120  | 0.82  | -0.24 | 153.35  | < 0.001 | 0.56           | 439.69 |
| 2023年<br>4月29日 | 開花2分                       | 120  | 1.18  | -0.05 | 863.59  | < 0.001 | 0.88           | 352.90 |
| 2023年<br>5月4日  | 開花6~7分                     | 120  | 1.25  | 0.18  | 1108.33 | < 0.001 | 0.90           | 400.02 |
| 2023年<br>5月5日  | 満開                         | 120  | 1.30  | -0.15 | 740.50  | < 0.001 | 0.86           | 421.25 |

z) 開花8分.

y) 落弁5分.

表 2-3 Blue Channel 画像の二値化閾値の最大値を 155 とした場合の撮影時期別の直線回帰式( $Y=aX + b$ )の適合性の評価

| 撮影年月日          | 開花状況                       | データ数 | 傾き(a) | 切片(b) | F値      | p値      | R <sup>2</sup> | AIC    |
|----------------|----------------------------|------|-------|-------|---------|---------|----------------|--------|
| 2021年<br>4月27日 | 開花1分                       | 100  | 0.81  | 0.11  | 164.53  | < 0.001 | 0.62           | 359.60 |
| 2021年<br>5月4日  | 開花4~6分                     | 100  | 1.00  | 0.31  | 1227.16 | < 0.001 | 0.93           | 295.73 |
| 2021年<br>5月7日  | 満開 <sup>z)</sup> ~<br>落弁1分 | 100  | 1.07  | 0.06  | 1149.82 | < 0.001 | 0.92           | 317.58 |
| 2022年<br>5月1日  | 満開                         | 100  | 0.78  | 0.25  | 1045.32 | < 0.001 | 0.91           | 360.95 |
| 2022年<br>5月6日  | 開花終期 <sup>y)</sup>         | 100  | 1.12  | 0.44  | 725.71  | < 0.001 | 0.88           | 419.38 |
| 2023年<br>4月26日 | 開花1分                       | 120  | 0.82  | -0.07 | 135.10  | < 0.001 | 0.53           | 448.05 |
| 2023年<br>4月29日 | 開花2分                       | 120  | 1.08  | 0.12  | 1033.56 | < 0.001 | 0.90           | 333.74 |
| 2023年<br>5月4日  | 開花6~7分                     | 120  | 1.09  | 0.17  | 1384.94 | < 0.001 | 0.92           | 375.61 |
| 2023年<br>5月5日  | 満開                         | 120  | 1.18  | 0.04  | 1083.00 | < 0.001 | 0.90           | 380.96 |

z) 開花8分.


y) 落弁5分.

### 2.3.2 PCAによるLAIの測定方法の検討


図2-4に天頂角数毎のPCA-LAIと実際LAIとの関係を、表2-4に直線回帰式の適合性の評価を示す。分散分析の結果、全ての回帰式で $p$ 値が0.001未満であり有意水準1%以下で有意であった。 $R^2$ については、5,4および3天頂角でそれぞれ0.65,0.65および0.66とこれらの天頂角数では差が見られなかったが、2天頂角で0.57と低かった。AICについて、5天頂角では220.21,4天頂角では219.02,3天頂角では217.57と天頂角数が少なくなるにつれてAICの値が低くなったが、2天頂角

では231.42と高くなった。回帰式の傾きについて、5天頂角では1.92,4天頂角では1.53,3天頂角では1.35,2天頂角では1.17と、天頂角数が少なくなるにつれて値が小さくなった。


図2-5に天頂角数毎の補正LAIと実際LAIとの関係を示す。相関係数について、5天頂角では0.79,4天頂角では0.80,3天頂角では0.84と、天頂角数が少なくなるにつれて値が高くなったが、2天頂角では0.77と低くなった。回帰式の傾きおよび切片は、3天頂角でそれぞれ1.07,0.04と、補正LAIが実際LAIに最も近くなった。




(a) 5天頂角



(b) 4天頂角



(c) 3天頂角



(d) 2天頂角

図2-4 天頂角数毎のPCA-LAIと実際LAIの関係

表 2-4 PCA-LAI と実際 LAI の直線回帰式( $Y=aX + b$ )の適合性の評価

| LAI     | PCA-LAI の天頂角数 | データ数 | 平均値  | 傾き (a) | 切片 (b) | F 値    | p 値     | R <sup>2</sup> | AIC    |
|---------|---------------|------|------|--------|--------|--------|---------|----------------|--------|
| 実際 LAI  | —             | 60   | 7.27 | —      | —      | —      | —       | —              | —      |
| PCA-LAI | 5 天頂角         | 60   | 3.54 | 1.92   | 0.49   | 108.66 | < 0.001 | 0.65           | 220.21 |
|         | 4 天頂角         |      | 4.16 | 1.53   | 0.88   | 111.99 | < 0.001 | 0.65           | 219.02 |
|         | 3 天頂角         |      | 4.54 | 1.35   | 1.15   | 116.17 | < 0.001 | 0.66           | 217.57 |
|         | 2 天頂角         |      | 4.59 | 1.17   | 1.91   | 80.26  | < 0.001 | 0.57           | 231.42 |

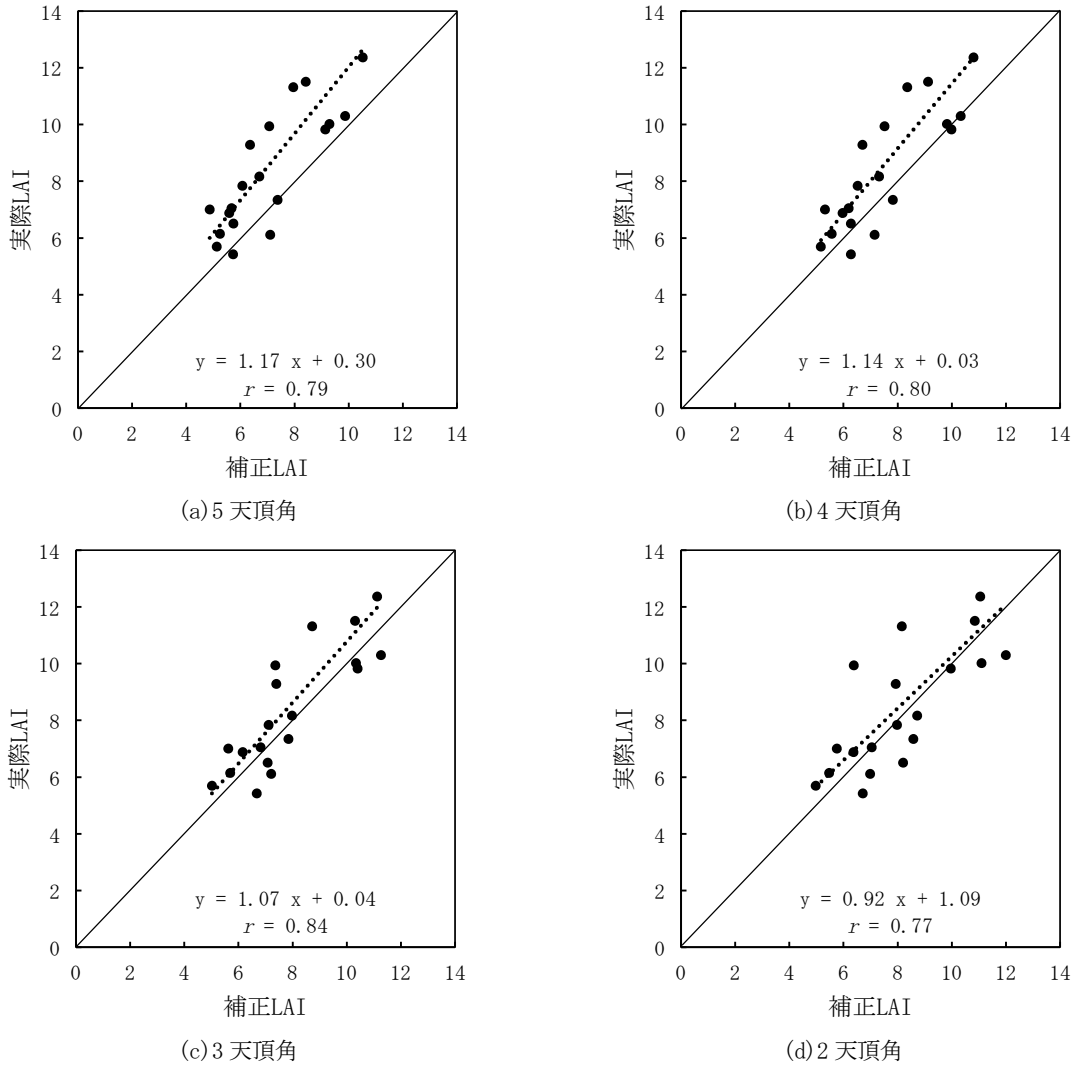


図 2-5 天頂角数毎の補正 LAI と実際 LAI の関係

2.3.3 花量, 収量および LAI の関係

図 2-6 に, 補正推定花量, 収量およびせん定前後の LAI の関係を示す。弱樹勢 1 樹のデータを除いた時の同年の補正推定花量と収量について, 2022 年では 0.28, 2023 年では 0.18 とほとんど相関が見られなかったが, 2 年合計では 0.82 とやや強い正の相関が見られた(図 2-6-a)。ヒリュウ台 6 樹のデータを除

いた時の前年収量と当年の補正推定花量について, 2021-2022 年では -0.54, 2022-2023 年では -0.15, 2023-2024 年では -0.41 と, ほとんど相関が見られないかやや弱い負の相関が見られたが, 3 年合計では -0.72 とやや強い負の相関が見られた(図 2-6-b)。せん定前後の LAI と補正推定花量には, それぞれ 0.20 および 0.10 とほとんど相関が見られなかった(図 2-6-c, d)。

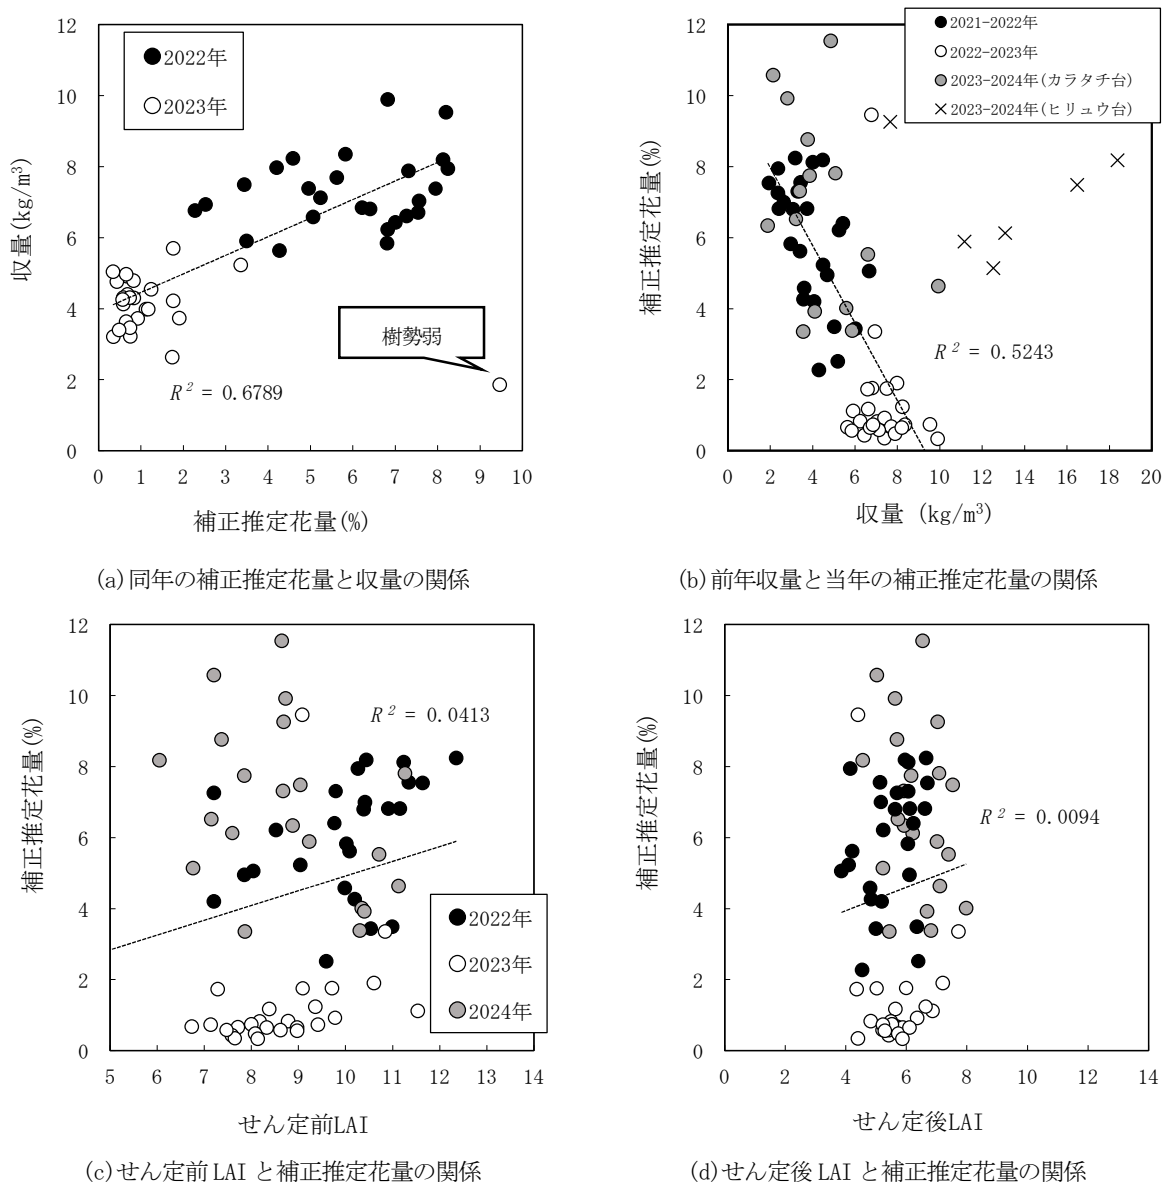


図 2-6 補正推定花量, 収量およびせん定前後の LAI の関係

## 2.4 考察

本章ではまず、空撮画像の二値化による花量の定量化方法を検討した。画像二値化における閾値を自動で決定するアルゴリズムはこれまでに複数開発されており、農業分野でもこれらを用いた技術が開発されている。例えば張ら(2002)は、ダイコンの間引き作業の自動化を目的として、Otsu の二値化法を応用しダイコン幼苗の良否を判定する手法を開発している。本章でも自動二値化アルゴリズムとして、Otsu の二値化法およびRenyiEntropy の二値化法を検討した。Otsu の二値化法は輝度値ヒストグラムを2クラスに分割した時に、クラス内分散が最も小さくなる輝度値を閾値として二値化を行う手法で、RenyiEntropy の二値化法は輝度値ヒストグラムを用いてエントロピーを計算し、そのエントロピーが最大となる閾値で二値化する手法である。調査の結果、自動二値化アルゴリ

ズは二値化閾値を手動設定した場合と比較して、花のみならず葉も白色となり誤認識が極めて多く(図2-3)、推定花量と実測花量に一貫した傾向が見られなかった(表2-1)。これは、いずれの自動二値化アルゴリズムも統計的に最もよく分離される二値化閾値を決定する方法であるため、完全に緑化していない黄緑色の葉や緑色の薄い裏側に向けた葉の存在により輝度値ヒストグラムの分散が画像毎に異なり、二値化閾値が画像毎に変動したことが原因と考えられた。一方で、二値化閾値を手動で設定した場合、検討した値のいずれにおいても、自動二値化アルゴリズムと比較して誤認識が少なかった(図2-3)。これは、輝度値ヒストグラムの分散に関わらず、花卉の画素値の情報に対応した二値化閾値を決定したためだと考えられた。

二値化閾値の手動設定による花の検出について、Dorj et al. (2012) は、タンゼリン樹体の側面画像における花数を計算

するために、Gaussian フィルタにより画像中のノイズを除去し RGB の各 Channel の値を 190 前後として二値化することで、高精度で花を検出できると報告している。また、Hočevar et al. (2014) は、リンゴ樹体の HSL 画像を用いて開花密度毎に閾値を設定し二値化することで、花房数を計測できると報告している。これらの手法は、各 Channel のそれぞれについて閾値を調整し二値化する手法である。一方で本章では、花の検出に有用な情報が全ての Channel に独立して存在するとは考えず、偽陽性と偽陰性を単純に制御できるよう、単一の輝度情報に変換し二値化処理を行う手法を検討した。すなわち、RGB 画像を NTSC 加重平均法により 8-bit グレースケール画像に変換し二値化する方法である。また、比較として RGB または HSB の各 Channel 画像を二値化する方法も検討した。推定花量と実測花量との関係の比較の結果、RGB 画像、Red Channel 画像および Blue Channel 画像は二値化閾値の最大値が一定の範囲で大きくなるにつれて  $R^2$  が高く、AIC が低くなった。また、Saturation Channel 画像は二値化閾値の最小値が一定の範囲で小さくなるにつれて  $R^2$  が高く、AIC が低くなった(表 2-1)。二値化閾値の最大値が大きくなるほど(最小値が小さくなるほど)誤認識は少なくなるが、花の情報も失われる。また、誤認識の割合も画像毎に一定ではない可能性がある。そこで、推定花量の平均値が実測花量の平均値に最も近く、 $R^2$  が高く、AIC の低い RGB 画像の二値化閾値 195 および Blue Channel 画像の二値化閾値 155(表 2-1)について、撮影時期別にデータを分割し、推定花量と実測花量を比較した。その結果、AIC は開花程度による一定の傾向が見られなかったが、 $R^2$  は開花 1 分以外の調査日で 0.84~0.90 および 0.88~0.93 と高かった(表 2-2, 2-3)。NTSC 加重平均法は人間の視覚感度に基づいた重み付けがされており、Green の重みが大きく、Blue の重みが小さい(式(2-1))。背景の Blue の影響が軽減され、結果として背景が暗く表示されやすくなったことから、背景と白色の花とのコントラストが高まり、Blue Channel 画像と同様に RGB 画像の二値化も花が検出しやすくなったと考えられた。したがって、土佐文旦の着花量を定量化する方法として、空撮した RGB 画像を NTSC 加重平均法で 8-bit グレースケール画像に変換し、閾値の最小値 0 および最大値 195 で二値化する手法、または Blue Channel 画像を最小値 0 および最大値 155 で二値化する手法が利用できると考えられた。ただし、撮影条件毎に推定花量と実測花量の関係にばらつきが見られ、開花状況による一定の傾向は見られなかった(表 2-2, 2-3)。そのため、実測花量を正確に把握するためには、撮影画像の一部を用いて算出した推定花量から実測花量を予測する回帰式を作成し補正することで、園地全体の花量の定量化が可能となると考えられた。なお、開花初期(開花 1 分ごろ)の  $R^2$  は他の開花程度と比較して低かった(表

2-2, 2-3) が、これは完全に白化していない蕾が存在したため、推定花量の算出時期として適当ではないと考えられた。

本章では次に、PCA の測定方法を検討した。PCA による LAI の推定を試みた結果、AIC は 3 天頂角で最も低くなり、2 天頂角で最も高くなった。一方で、回帰式の傾きは天頂角数が少なくなるほど値が小さくなったが、いずれの天頂角数でも PCA-LAI が実際 LAI より過小評価された(図 2-4, 表 2-4)。丸山ら(2005)は、イネの群落において、出穂期のように葉群傾斜角が鉛直に近いほど PCA による植物面積指数の測定値が過小評価すると報告している。土佐文旦は樹冠下部ほど枝葉が下垂する(鉛直に近づく)傾向があるため、樹冠下部のデータが含まれる天頂角数が多くなるほど、PCA-LAI が実際 LAI より過小評価されたと考えられた。よって、測定に用いる天頂角数は少ないほどよいが、2 天頂角では樹体上部の葉の分布情報にのみに基づいて LAI を算出するため、ばらつきが大きくなり測定には不相当であると考えられた。さらに、補正式の検証の結果、3 天頂角では相関係数が 0.84 と最も高く、回帰式の傾きおよび切片がそれぞれ 1.07, 0.04 と補正 LAI が実際 LAI に最も近似した(図 2-5)。したがって、PCA による LAI の測定には 3 天頂角を用い、回帰式による補正を行うことで実際の LAI を推定可能であると考えられた。

本章では最後に、花量、収量および LAI の関係から、これら測定技術の実用性を評価した。その結果、2022 年と 2023 年を合わせた同年の補正推定花量と収量にはやや強い正の相関が見られた(図 2-6-a)。池田ら(1991)は、ウンシュウミカンにおいてアドバシールンからの開花時の空撮画像から得られたモニタ花量と収穫果数には、正の相関が見られたと報告しており、本章の結果は収量重量での算出であるものの、同等の傾向が見られた。なお、各年の補正推定花量と収量にはほとんど相関が見られず、特に 2023 年の補正推定花量および収量が少なかったが、これは 2023 年が 1 月下旬の低温(1 月 25 日の最低気温 -3.9 °C、気象庁 AMeDAS 高知気象観測所データ)の影響により、特に樹冠上部の着花量および着果量が減少したためと考えられた。また、前年収量と当年補正推定花量の関係にはヒリュウ台を除き、やや強い負の相関が見られた(図 2-6-b)。小林ら(1995)は、青島温州においてヒリュウ台は樹冠容積および樹冠面積がカラタチ台と比較して小さくなり、1 樹当たり収量も少なくなるが、樹冠容積当たり収量が多くなることを報告している。本章で用いたヒリュウ台土佐文旦もカラタチ台と比較して樹冠容積当たり収量が多くなり、カラタチ台とは異なる傾向を示したと考えられた。以上より、台木により異なる傾向が見られたものの、補正推定花量と収量には関連性が認められ、空撮画像の二値化によって定量化した着花量は、収量を予測するための生理生態指標として実用性があると考えられ

た。一方で、補正推定花量と収量の関係とは異なり、せん定前後のLAIと補正推定花量にはほとんど相関が見られなかった(図2-6-c, d)。木原, 小中原(2000)は、ウンシュウミカンにおいて表年における発育枝の発生促進およびせん定による着花、着果調節が隔年結果対策として重要であると報告している。しかし、本章の結果は、露地土佐文旦において開花直前のLAIの調節が着花量に影響しなかったことを示した。

以上より、露地土佐文旦における開花期の空撮画像から、着花量を定量化する技術を開発した。同年の補正推定花量と収量には正の相関が見られたことから、本手法を用いることで、開花期に収量を予測できると考えられる。また、PCAによるLAIの測定方法を確立した。せん定前後のLAIと補正推定花量にはほとんど相関が見られなかったが、本手法を用いて生育期間中のLAIをモニタリングし、肥培管理を改善することで生産性の向上につながると考えられる。

## 2.5 参考文献

- 1) Akaike, H. (1998) Information Theory and an Extension of the Maximum Likelihood Principle, Selected Papers of Hirotugu Akaike, Springer New York, New York, 199-213.
- 2) Dorj, U. O., M. Lee and Diyan-ul-Imaan (2012) A New Method for Tangerine Tree Flower Recognition, Communications in Computer and Information Science, 353:49-56.
- 3) Hočevar, M., B. Širok, T. Godeša and M. Stopar (2014) Flowering Estimation in Apple Orchards by Image Analysis, Precision Agriculture, 15:466-478.
- 4) 池田富喜夫, 森永邦久, 永田賢嗣 (1991) カンキツの樹液や樹冠映像などの生体情報による収量予測, 四国農業試験場報告, 54:111-120.
- 5) カンキツの調査方法編集委員会 (1987) カンキツの調査方法, 農林水産省果樹試験場興津支場, 静岡, 3.
- 6) Kapur, J. N., P. K. Sahoo and A. K. C. Wong (1985) A New Method for Gray-Level Picture Thresholding Using the Entropy of the Histogram, Computer Vision, Graphics, and Image Processing, 29(3):273-285.
- 7) 木原武士, 小中原実 (2000) ウンシュウミカンにおける隔年結果の現状と対策, 果樹試験場報告, 34:111-136.
- 8) 小林康志, 大野文征, 岡田正道, 鹿野英士, 牧田好高, 加々美裕, 井口功, 原節生, 黒柳栄一, 佐々木俊之 (1995) ‘ヒリュウ’ 台木が ‘青島温州’ の生育・収量・果実品質に及ぼす影響, 静岡県柑橘試験場研究報告, 26:23-30.
- 9) 丸山篤志, 桑形恒男, 大場和彦 (2005) プラントキャノピーアナライザによる植物面積指数の測定誤差とその葉群傾斜角への依存性, 農業気象, 61(4):229-233.
- 10) 農林水産省 (2022) 令和4年生産農業所得統計, <<https://www.e-stat.go.jp/stat-search/files?page=1&layout=datalist&toukei=00500206&tstat=000001015617&cycle=7&year=20220&month=0&tclass1=000001019794&tclass2=000001215200>>, 2025年2月15日参照.
- 11) Otsu, N. (1979) A Thresholding Selection Method from Gray-Level Histograms, IEEE Transaction on Systems, Man, and Cybernetics, SMC-9(1):62-66.
- 12) Treder, W., K. Klankowski, A. Tryngiel-Gač and K. Wójcik (2021) Application of ImageJ Software in the Assessment of Flowering Intensity and Growth Vigor of Pear Trees, Journal of Horticultural Research, 29(2):85-94.
- 13) 山本晴彦, 岩谷潔 (2022) デジタルカメラを利用したカンキツ樹の総葉面積の計測, 農業技術大系果樹編 第1-I巻, 農山漁村文化協会, 東京, 技22の20-技22の22.
- 14) 張樹槐, 高橋照夫, 福地博, 嵯峨紘一 (2002) 根菜類野菜の間引き作業の自動化に関する研究(第2報) 自動2値化によるダイコン幼苗の認識方法, 農業機械学会誌, 64(2):71-77.

### 第 3 章 葉面積指数を用いたユズのせん定の定量化

#### 3.1 はじめに

本章では、高知県が全国で最も栽培面積の多いユズ(農林水産省 2021)に焦点を当て、PCA の測定方法を検討した。さらに、隔年結果性および収量性の観点から、ユズにおける適正なせん定量を LAI により指標化した。

#### 3.2 材料および方法

##### 3.2.1 着果樹を用いた PCA による LAI 測定方法の検討

PCA によるユズの LAI 測定に最適な測定位置および PCA-LAI 算出に用いる天頂角数について、着果樹を用い検討した。場内(果樹試 A 園, 図 3-1)に植栽間隔 3.0×4.0 m で植えられた 20~24 年生の開心自然形のユズ「公文系」10 樹を供試し、2019 年

8 月下旬~9 月に全葉数、個葉面積および樹幅(長径幅、短径幅)を測定した後、樹冠面積(m<sup>2</sup>)を式(3-1)で、実際 LAI を式(3-2)で算出した。なお個葉面積は、樹内で中庸な葉を 20 枚/樹ずつ採取し、スキャナーでスキャンして、フリーソフトウェアの LIA for Win32 を用いて算出した。PCA-LAI は、曇天日の 9 月 30 日の日中に 90° のビューキャップを装着した PCA(LAI-2200C)を用い、山本、岩谷(2022)の方法を参考に、主幹中心から 30, 40, 50, 60, 70, 80, 90 cm 離れた 4 方位(東西南北)の位置より測定した。付属の解析ソフトの FV2200 を用い、天頂角 5 つ(7, 23, 38, 53, 68°, 以下、5 天頂角)、4 つ(7, 23, 38, 53°, 以下、4 天頂角)および 3 つ(7, 23, 38°, 以下、3 天頂角)により、光路長を Horizontal(default)として解析した(図 3-2)。

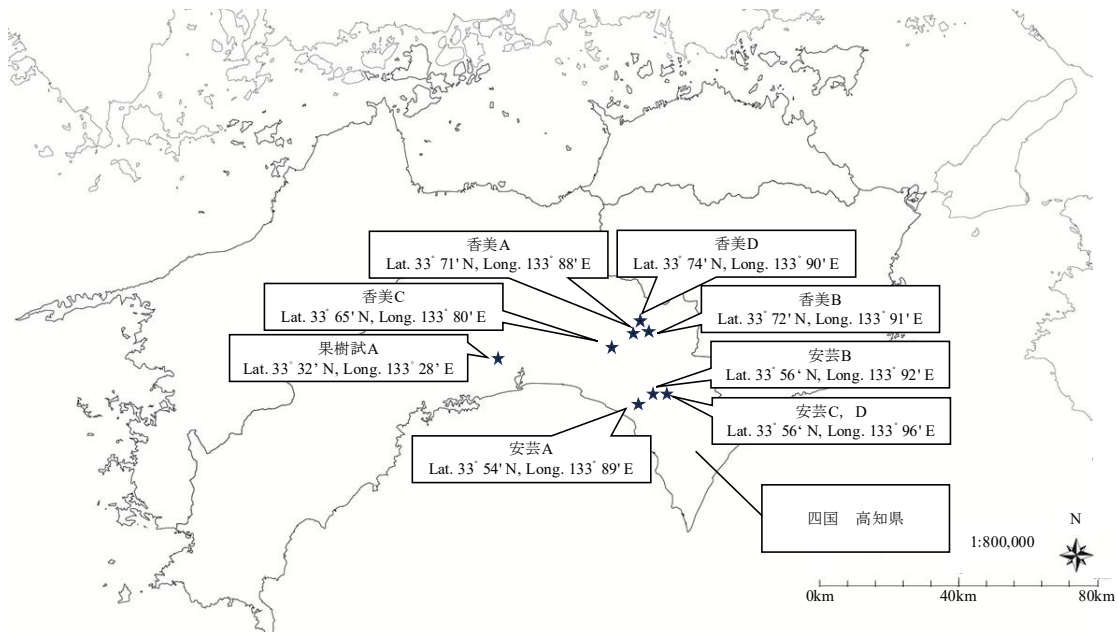


図 3-1 調査園地の位置

$$\text{樹冠面積 (m}^2\text{)} = \left( \frac{\text{樹冠長径幅 (m)} + \text{樹冠短径幅 (m)}}{2 \times 2} \right)^2 \times \pi \quad (3-1)$$

$$\text{実際 LAI} = \frac{\text{全葉数} \times \text{個葉面積 (m}^2\text{)}}{\text{樹冠面積 (m}^2\text{)}} \quad (3-2)$$

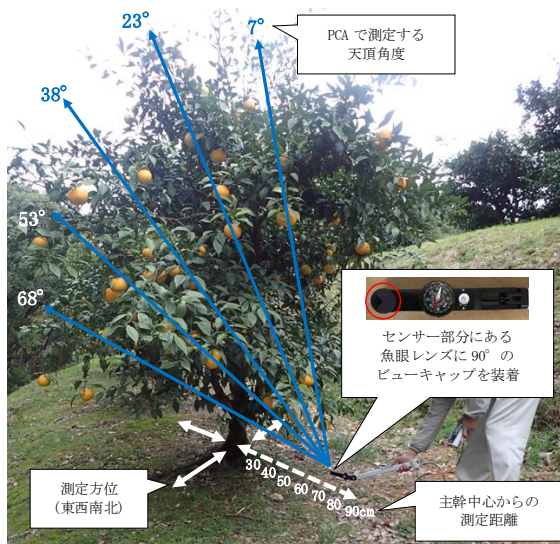


図3-2 PCAによる測定の様子

### 3.2.2 未着果樹を用いたPCAによるLAI測定方法の検証

着果樹を用い検討したPCA-LAIの測定方法について、未着果樹を用いて検証した。場内に植栽間隔 $3.0 \times 4.0$  mで植えられた19~26年生の開心自然形のユズ「公文系」11樹、計20データを用いた。実際LAIは、2019年2月下旬(せん定前)、3月中旬(せん定後)および2022年2月下旬(せん定前)、3月下旬(せん定後)に、「3.2.1 着果樹を用いたPCAによるユズのLAI測定方法の検討」と同様の方法で算出した。PCA-LAIは、 $90^\circ$ のビューキャップを装着したPCAを用い主幹中心から80 cm離れた4方位の位置より、曇天日の2019年2月27日(せん定前)、3月25日(せん定後)、2022年2月9日(せん定前)および3月25日(せん定後)の日中に測定した。「3.2.1 着果樹を用いたPCAによるユズのLAI測定方法の検討」と同様に付属の解析ソフトを用い、5天頂角、4天頂角および3天頂角で算出し比較した。各天頂角で算出したPCA-LAIを説明変数、実際LAIを目的変数とした回帰分析(直線回帰)について、分散分析、自由度修正済み

決定係数(以下、 $R^2$ )および赤池情報量基準(以下、AIC)で評価した。分散分析の実施および $R^2$ の算出には、エクセル統計4.07を用いた。

### 3.2.3 PCA-LAIによるせん定量の指標化

高知県内の生産者園の実態調査から生産性の高い園地を抽出し、収量とPCA-LAI等との関係を解析して、適正なせん定量を検討した。高知県安芸市および香美市の平坦地に植栽されている計8園地から、平均的な樹を4樹ずつ選び調査対象とした。表3-1に現地生産者園地の概要を、図3-1に調査園地の位置を示す。施肥や防除等は生産者慣行とし、全園とも完全着色後に収穫した。樹冠面積および樹冠容積は、2018年11月、2019年11月、2021年1月および2022年1月に箱尺で樹幅(長径幅、短径幅)および高さを測定し、楕円および半楕円体に近似として算出した。収量は、2018~2021年の11月に収穫重量を調査した。旧高知県山間農業試験場の調査結果(表3-2)から、開心自然形における樹冠容積当たりの基準収量を $2.1 \text{ kg/m}^3$ とし、 $2.1 \text{ kg/m}^3$ 以上を高収量性園、 $2.1 \text{ kg/m}^3$ 未満を低収量性園とした。隔年結果指数は、Hoblyn et al. (1936)の報告に準じて式(3-3)より算出した。安定生産上許容できる値を0.30と設定し、0.30未満を低隔年結果性園、0.30以上を高隔年結果性園とした。収量性および隔年結果性の組み合わせにより調査園地を4つに分類し、高収量性かつ低隔年結果性と分類された園地のPCA-LAIを調査した。PCA-LAIは、2018年11月、2019年3~4月、11月、2020年4月、2021年1月および3~4月の曇天日中に、主幹中心から80 cm離れた4方位の位置で測定し、4天頂角から算出した。2018年11月、2019年11月および2021年1月に測定したPCA-LAIをせん定前LAI、2019年3~4月、2020年4月および2021年3~4月に測定したPCA-LAIをせん定後LAI、せん定前LAI - せん定後LAIをLAI減少量、LAI減少量/せん定前LAI $\times 100$ をLAI減少率(%)とした。

$$\text{隔年結果指数} = \frac{|\text{当年収量}(\text{kg/m}^3) - \text{前年収量}(\text{kg/m}^3)|}{\text{当年収量}(\text{kg/m}^3) + \text{前年収量}(\text{kg/m}^3)} \quad (3-3)$$

表 3-1 現地生産者園地の概要

| 園地名  | 品種<br>系統 | 樹齢<br>(年) <sup>z)</sup> | 植栽間隔<br>(m) | 樹形    | 樹高<br>(m) <sup>y)</sup> | 樹冠容積<br>(m <sup>3</sup> ) <sup>x)</sup> | 樹冠面積率<br>(%) <sup>w)</sup> |
|------|----------|-------------------------|-------------|-------|-------------------------|---|----------------------------|
| 安芸 A | 海川系      | 14                      | 4.0 × 4.0   | 開心自然形 | 2.4                     | 16.7                                    | 64.1                       |
| 安芸 B | 海川系      | 14                      | 4.0 × 2.5   | 開心自然形 | 3.2                     | 20.8                                    | 97.8                       |
| 安芸 C | 海川系      | 14                      | 4.0 × 3.0   | 開心自然形 | 3.1                     | 18.2                                    | 72.6                       |
| 安芸 D | 海川系      | 15                      | 3.5 × 3.0   | 開心自然形 | 3.1                     | 18.4                                    | 83.7                       |
| 香美 A | 公文 2 号   | 不明                      | 3.5 × 3.0   | 開心形   | 2.6                     | 11.3                                    | 61.5                       |
| 香美 B | 公文系      | 24                      | 3.0 × 3.5   | 開心形   | 2.2                     | 9.7                                     | 62.9                       |
| 香美 C | 公文系      | 26                      | 4.0 × 3.5   | 開心形   | 2.5                     | 13.2                                    | 56.8                       |
| 香美 D | 公文系      | 10                      | 3.0 × 2.7   | 開心形   | 2.3                     | 8.3                                     | 68.1                       |

z) 2018 年時点の樹齢。

y) 2018~2021 年の各年 11 月の平均値。

x) 半楕円体に近似として算出。2018~2021 年の各年 11 月の平均値。

w) 楕円に近似とした 1 樹当たりの樹冠面積と、植栽間隔から算出した 10 a 当たり植栽本数より算出。

表 3-2 基準収量の算出方法

| 調査年  | 樹齢<br>(年) | 1 樹当たり収量 |        | 平均果実重<br>(g) | 樹冠容積<br>(m <sup>3</sup> ) | 収量<br>(個/m <sup>3</sup> ) | 収量(kg/m <sup>3</sup> ) |
|------|-----------|----------|--------|--------------|---------------------------|---------------------------|------------------------|
|      |           | 個数       | 重量(kg) |              |                           |                           |                        |
| 1978 | 8         | 165.8    | 21.4   | 132.0        | 11.1                      | 14.9                      | 2.0                    |
| 1979 | 9         | 360.0    | 37.6   | 109.0        | 16.3                      | 22.1                      | 2.4                    |
| 1980 | 10        | 199.1    | 20.1   | 121.0        | 13.7                      | 14.5                      | 1.8                    |
| 1981 | 11        | 381.0    | 37.8   | 104.0        | 17.1                      | 22.3                      | 2.3                    |
| 平均   | —         | 276.5    | 29.2   | 116.5        | 14.6                      | 18.5                      | 2.1                    |

注 1) 昭和 56 年度高知県山間農業試験場試験研究実績報告書より抜粋。

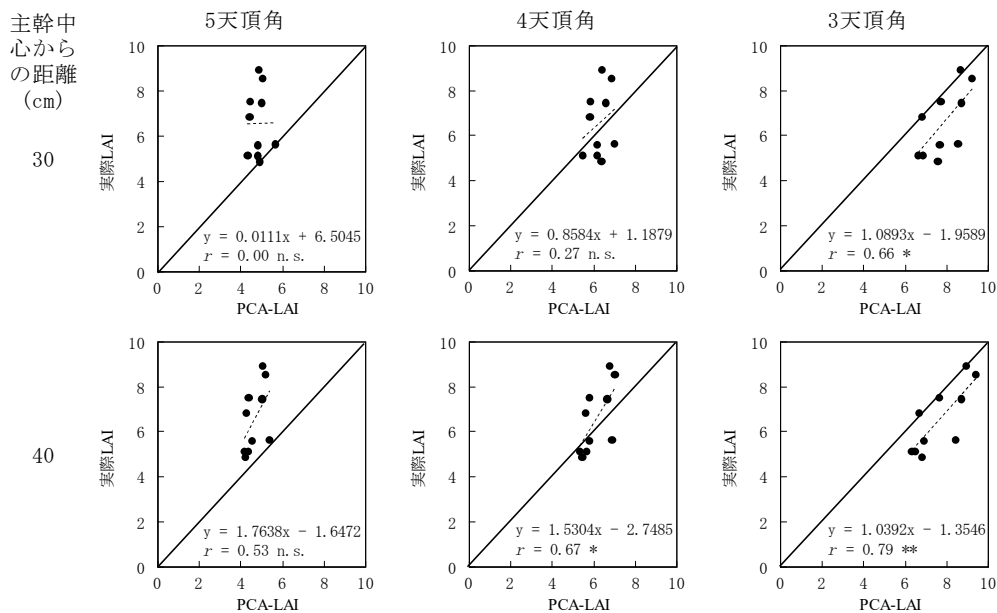
2) 旧物部村(現香美市), 8 年生, 開心自然形, 階段畑で段幅が 2.3~3.9 m, 株間が 3.4~5.0 m の 1 列植, 13 本を調査。

### 3.3 結果

#### 3.3.1 着果樹を用いた PCA による LAI 測定方法の検討

着果樹における PCA-LAI は、いずれの主幹中心からの距離の測定でも、5 天頂角での算出時に実際 LAI より低くなる傾向であったが、4 天頂角の算出では同等で、3 天頂角の算出では高く

なる傾向であった。また、4 天頂角での算出時の主幹中心からの距離は、80 cm とした場合に相関係数 0.82 と最も強い正の相関が見られた。無相関の検定において有意差が認められたいずれの回帰式においても、切片は -1.35~ -4.19 とマイナスであった(図 3-3)。



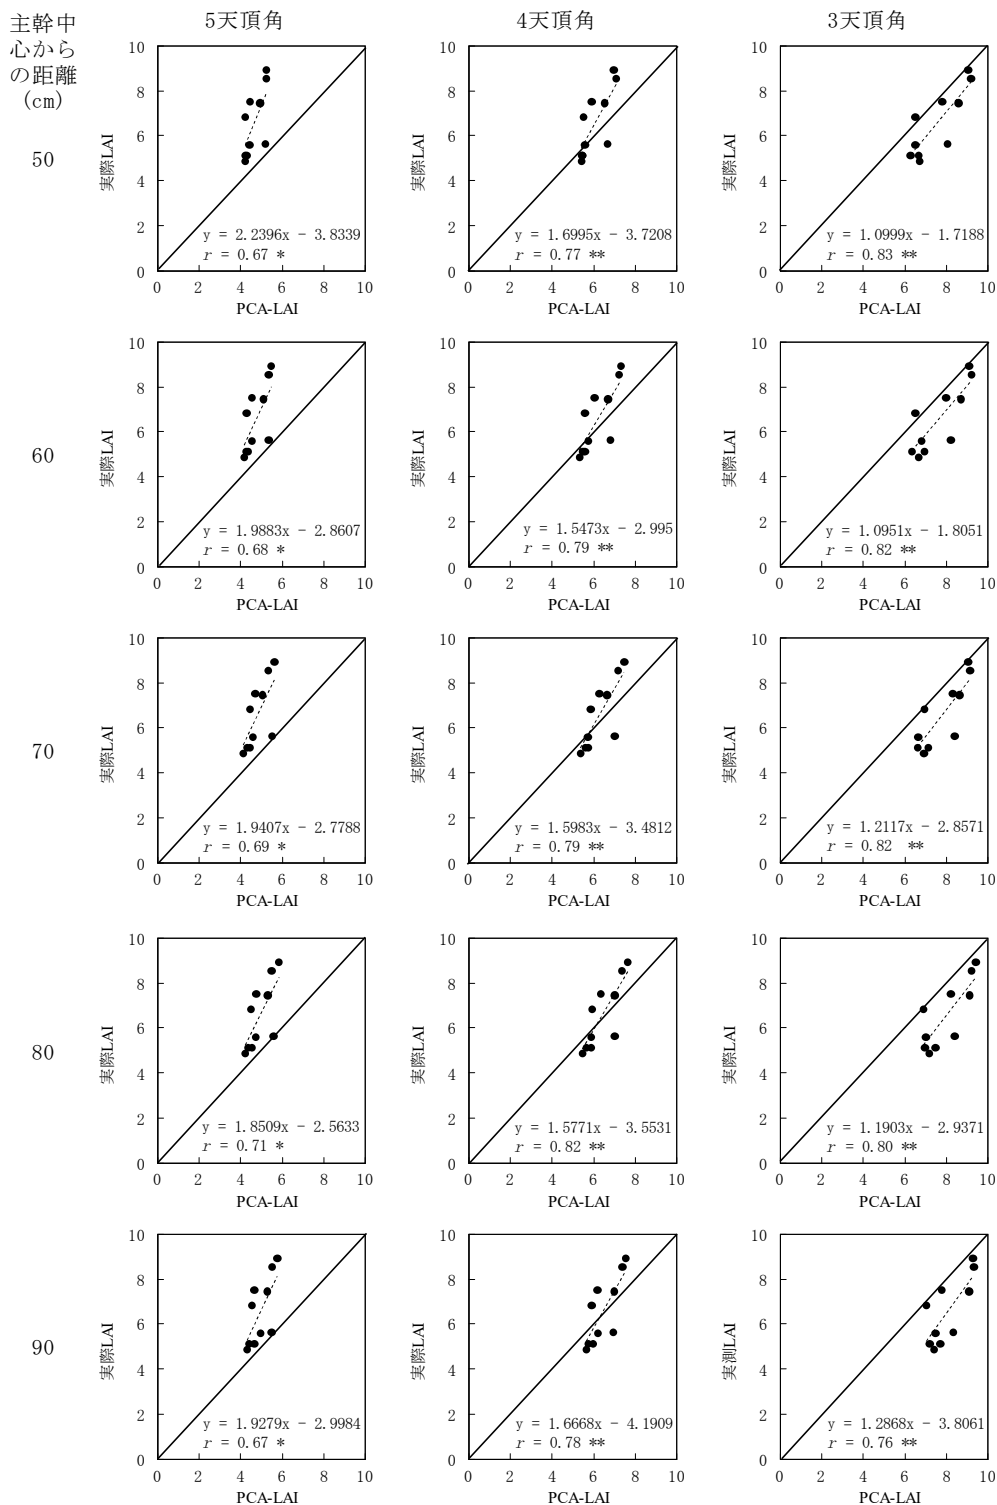


図 3-3 着果した樹体における PCA-LAI と実際 LAI の関係

注) 無相関の検定により, \*\*は 1%水準で, \*は 5%水準で有意差あり, n. s. は有意差なし。

### 3.3.2 未着果樹を用いた PCA による LAI 測定方法の検証

せん定により LAI を変化させた未着果樹において PCA-LAI と実際 LAI の関係を調査した結果, 4 天頂角の  $R^2$  は 0.61 と他の天頂角と比較してやや低く, AIC は 52.99 とやや高かったが, 差は小さかった。回帰直線の傾きは, 5 天頂角での算出時に

1.22 と PCA-LAI が実際 LAI より過小評価される傾向で, 3 天頂角での算出時に 0.64 と PCA-LAI が実際 LAI より過大評価される傾向であったのに対し, 4 天頂角での算出では 0.88, 切片は +0.21 と, PCA-LAI の値が最も実際 LAI に近かった (図 3-4, 表 3-3)。

表 3-3 未着果の樹体における PCA-LAI と実際 LAI の直線回帰式( $Y=aX + b$ )の適合性の評価

| LAI       | PCA-LAI の<br>天頂角数 | データ<br>数 | 平均値  | 傾き<br>(a) | 切片<br>(b) | F 値   | p 値     | R <sup>2</sup> | AIC   |
|-----------|-------------------|----------|------|-----------|-----------|-------|---------|----------------|-------|
| 実際<br>LAI | —                 | 20       | 3.93 | —         | —         | —     | —       | —              | —     |
| PCA-LAI   | 5 天頂角             | 20       | 3.24 | 1.22      | -0.03     | 33.09 | < 0.001 | 0.63           | 52.08 |
|           | 4 天頂角             |          | 4.23 | 0.88      | 0.21      | 30.82 | < 0.001 | 0.61           | 52.99 |
|           | 3 天頂角             |          | 5.29 | 0.64      | 0.55      | 33.07 | < 0.001 | 0.63           | 52.09 |




図 3-4 未着果の樹体における PCA-LAI と実際 LAI の関係




図 3-5 現地生産者園の収量性

注 1) 各園 4 樹調査, 2018~2021 年の平均値  
 2) エラーバーは標準偏差を示す。  
 3) ①は高収量性×低隔年結果性園, ②は高収量性×高隔年結果性園, ③は低収量性×低隔年結果性園, ④は低収量性×高隔年結果性園を示す。

3.3.3 PCA-LAI によるせん定量の指標化

収量(kg/m<sup>2</sup>)は, 安芸 A, C, D 園および香美 B, C 園が基準収量より多かった(図 3-5). 隔年結果指数は, 安芸 C 園および香美 A, B, C 園が 0.30 未満と小さかった(図 3-6). せん定後 LAI は, 安芸 A 園および香美 A 園でそれぞれ 2.7 および 3.1 と低く, 安芸 D 園で 4.5 と高かった(図 3-7). LAI 減少量は, 安芸 C, D 園および香美 B, D 園で 2.0 以下と小さかった(図 3-8). LAI 減少率(%)は, 安芸 D 園および香美 B 園でそれぞれ 23.5 % および 24.7 % と低く, 安芸 A 園では 49.2 % と高かった(図 3-9). 高収量性かつ低隔年結果性と分類された安芸 C 園および香美 B, C 園におけるせん定後 LAI の平均値は 3.7(図 3-7), LAI 減少量の平均値は 1.7(図 3-8), LAI 減少率(%)の平均値は 30.6 % であった(図 3-9).




図 3-6 現地生産者園の隔年結果性

注 1) 各園 4 樹調査, 2018~2021 年の平均値  
 2) エラーバーは標準偏差を示す。  
 3) ①は高収量性×低隔年結果性園, ②は高収量性×高隔年結果性園, ③は低収量性×低隔年結果性園, ④は低収量性×高隔年結果性園を示す。




図3-7 現地生産者園のせん定後LAI

注1) 各園4樹をPCAにより調査, 2019~2021年の  
 平均値  
 2) エラーバーは標準偏差を示す。  
 3) ①は高収量性×低隔年結果性園, ②は高収量性  
 ×高隔年結果性園, ③は低収量性×低隔年結果性園,  
 ④は低収量性×高隔年結果性園を示す。




図3-9 現地生産者園のLAI減少率

注1) 各園4樹をPCAにより調査, 2019~2021年の  
 平均値  
 2) エラーバーは標準偏差を示す。  
 3) ①は高収量性×低隔年結果性園, ②は高収量性  
 ×高隔年結果性園, ③は低収量性×低隔年結果性園,  
 ④は低収量性×高隔年結果性園を示す。




図3-8 現地生産者園のLAI減少量

注1) 各園4樹をPCAにより調査, 2019~2021年の  
 平均値  
 2) エラーバーは標準偏差を示す。  
 3) ①は高収量性×低隔年結果性園, ②は高収量性  
 ×高隔年結果性園, ③は低収量性×低隔年結果性園,  
 ④は低収量性×高隔年結果性園を示す。

### 3.4 考察

ユズの新規就農者にとって、せん定は習得の難しい管理作業の一つである。特にせん定量は、前年の着果量や収穫時期、結果母枝の量や質、葉色、落葉量および幹腐病の罹患の有無等によって樹毎に決定する必要がある。せん定量が少ないと、枝葉が混み合いすぎて防除や収穫作業等に時間を要する(高知県ゆず振興対策協議会 2024)。一方、せん定量が多すぎる場合、樹形が乱れ、収量および品質が不安定となる(菊池ら 2009)。熟練生産者は前述の樹の状態を基に経験的に判断し、せん定量を調節しているが、ユズにおいて適正なせん定量の目安は明確となっていないため、栽培初心者は樹毎にせん定量を決定することに苦慮している。そこで、せん定量の指標としてLAIに着目した。いくつかの果樹で、収量はLAIに強く影響を受けることが明らかとなっている(塩崎ら 1992, 末沢, 土居 1985)が、カンキツ類においてもLAIの増加にしたがって収量は増加し、一定以上のLAIとなると、密植の弊害として収量が減少し始めることが認められている(橘, 中井 1989)。これらのことから、ユズにおいても、単位面積あるいは1樹当たりの収量を最大にする最適LAIが存在し、それを連年として維持できるようなせん定後のLAIを明らかにすることで、LAIをせん定量の目安として利用できると考えた。

着果樹を用いてPCAによるLAIの推定を試みた結果、露地ユズにおいても露地ウンシュウミカンとほぼ同様の設定で推定できる可能性が示唆されたが、測定に最適な主幹からの距離は80 cmと、ウンシュウミカンの60 cmとやや異なった。また、

いずれの天頂角数の回帰式においても切片がマイナスとなった(図3-3)。これは8~9月の果実肥大期に測定したため、センサーが果実を葉と見なして評価した可能性や、果実の重みによる枝葉の下垂が影響した可能性が考えられた。そのため、せん定前後の未着果の樹体を用いてPCAの精度を検証した。その結果、4天頂角を用いた場合のPCA-LAIが最も実際LAIに近く、回帰直線もほぼ原点を通った(図3-4、表3-3)。よって、90°のビューキャップを装着したPCAを用い、主幹中心から距離80cmで測定し、かつ4天頂角を用いて解析することで、未着果のユズではLAIを比較的正確に推定できると考えられた。なお今回は、植栽間隔が4.0×3.0mと樹間の比較的広い園地での検討であったため、樹と樹が交差するような密植園の測定では、天頂角数を少なくすることを検討する必要がある。

次に、県内生産者園の実態調査から生産性の高い園地を抽出し、収量とPCA-LAI等との関係を解析して、適正なせん定量を検討した。4年間の調査から、隔年結果指数が0.30未満の毎年安定した収量(低隔年結果性)かつ2.1 kg/m<sup>3</sup>以上の高い収量(高収量性)である3園地(安芸C園、香美B園および香美C園)を抽出した(図3-5、図3-6)。この3園地は樹形、樹高および樹冠容積が異なるものの、樹冠面積率が80%以下と低く(表3-1)、せん定後LAI、LAI減少量およびLAI減少率(%)は比較的近い値であった(図3-7、図3-8、図3-9)。一方で、低収量性かつ高隔年結果性の2園地について、安芸B園は樹冠面積率が97.8%と高く、香美D園は樹冠面積率が68.1%と低いものの、植栽間隔が狭く樹冠容積が小さかった(表3-1)。また、高隔年結果性の安芸A園および低収量性の香美A園は、樹冠面積率がそれぞれ64.1%および61.5%と低いものの(表3-1)、せん定後LAIがそれぞれ2.7および3.1と他園より低かった(図3-7)。さらに、高隔年結果性の安芸D園は樹冠面積率が83.7%(表3-1)かつせん定後LAIが4.5と他園より高かった(図3-7)。このことから、ユズにおける適正なせん定量の目安について、一般的な栽植密度である植栽間隔が概ね4.0×3.0mの場合、樹冠面積率は80%以下とし、せん定後LAIは3.7、LAI減少量は1.7、LAI減少率は30.6%とするのが妥当と考えられた。ただし、隔年結果

性および収量性はせん定量のみならず、土質、施肥量、気象条件および収穫時期等にも影響されることに留意が必要である。

以上より、ユズにおけるPCAによるLAIの測定方法を確立し、適正なせん定量の目安を明らかにした。本手法を用いてせん定量を一定にすることで、生産量および出荷量が安定し、出荷量の予測も容易になると考えられる。

### 3.5 参考文献

- 1) Hoblyn, T. N., N. H. Grubb, A. C. Painter and B. L. Wates (1936) Studies in Biennial Bearing-1, Journal of Pomology and Horticultural Science, 14:39-76.
- 2) 菊池毅洋, 高木信雄, 喜多景治, 三堂博昭, 崎本孝江 (2009) カンキツの剪定方法の違いによる樹のエイジング調節, 愛媛県農林水産研究所果樹研究センター研究報告, 1:17-23.
- 3) 高知県ゆず振興対策協議会 (2024) ゆず栽培マニュアル 第2版, 高知, 28-32.
- 4) 農林水産省 (2021) 令和3年産特産果樹動態等調査, <https://www.e-stat.go.jp/stat-search/files?page=1&layout=datalist&toukei=00500503&tstat=000001020907&cycle=7&year=20210&month=0&tclass1=000001032892&tclass2=00001213907>, 2025年2月15日参照.
- 5) 塩崎雄之輔, 菊池卓郎 (1992) 葉面積指数および樹勢が開心形リンゴ樹の収量に及ぼす影響, 園芸学会雑誌, 60(4):827-832.
- 6) 末澤克彦, 土居新一 (1985) キウイフルーツの収量構成要因の定量化(第1報) 最適葉面積指数の推定, 香川県農業試験場研究報告, 37:48-54.
- 7) 橘温, 中井滋郎 (1989) 異なった栽植密度及び栽培条件におけるワセウシユウの収量と葉面積指数との関係, 園芸学会雑誌, 57(4):561-567.
- 8) 山本晴彦, 岩谷潔 (2022) デジタルカメラを利用したカンキツ樹の総葉面積の計測, 農業技術大系果樹編 第1-I巻, 農山漁村文化協会, 東京, 技22の20-技22の22.

## 第4章 ヌズの着果数推定に用いる果実検出モデルの比較検討

### 4.1 はじめに

本章では、ヌズに焦点を当て、樹体の空撮画像から着果数を推定する手法を確立するために、データ拡張によりデータセットの画像数を違えて学習させた果実推定モデルの予測精度を3種類のYOLOモデルで比較するとともに、特定の園地および特定の天候の画像データセットにより学習させたYOLOモデルの予測精度を比較検討した。

### 4.2 材料および方法

#### 4.2.1 UAV画像の取得

画像は、場内の2つのヌズ園(果樹試AおよびB園)および高知県香美市の2つの生産者園(以下、香美FおよびH園)で取得

した。表4-1に調査園地の概要を、図4-1に調査園地の位置を示す。2020年の果樹試B園および2023年の香美H園は晴天時に撮影し、他園および他年は曇天時に撮影した。また、2023年の香美F園およびH園は未完着の果実を撮影し、他園は完全着色の果実を撮影した。撮影には、空撮用UAVのMavic miniを用いて地上高5.0~9.0mから、樹体に対して鉛直方向に1枚毎に撮影した。ISO感度がオート(100~1600)、シャッター速度が4~1/8000秒の設定とした。なお、Mavic miniの機体サイズは小型であり、樹冠上部から機体まで3m以上離れていたため、撮影へのUAVによるダウンウォッシュの影響はほとんどなかった。画像データはサイズ4000×2250pixel、解像度72dpi、JPEGファイル形式で保存した。

表4-1 調査園地の概要

| 分類 | 園地名  | 撮影年月日      | 樹数 | 撮影日の天候 | 撮影日の果実着色 | 収穫年月日      |
|----|------|------------|----|--------|----------|------------|
| 学習 | 果樹試A | 2020/10/28 | 40 | 曇天     | 完全着色     | 2020/11/6  |
| 学習 | 果樹試A | 2021/10/31 | 45 | 曇天     | 完全着色     | 2021/11/11 |
| 検証 | 果樹試A | 2022/10/27 | 15 | 曇天     | 完全着色     | 2022/11/8  |
| 学習 | 果樹試B | 2020/10/30 | 20 | 晴天     | 完全着色     | 2020/11/4  |
| 検証 | 果樹試B | 2021/11/5  | 15 | 曇天     | 完全着色     | 2021/11/12 |
| 学習 | 果樹試B | 2022/10/27 | 20 | 曇天     | 完全着色     | 2022/11/2  |
| 検証 | 香美F  | 2023/10/18 | 15 | 曇天     | 未着色      | 2023/11/7  |
| 検証 | 香美H  | 2023/10/25 | 10 | 晴天     | 未着色      | 2023/11/9  |

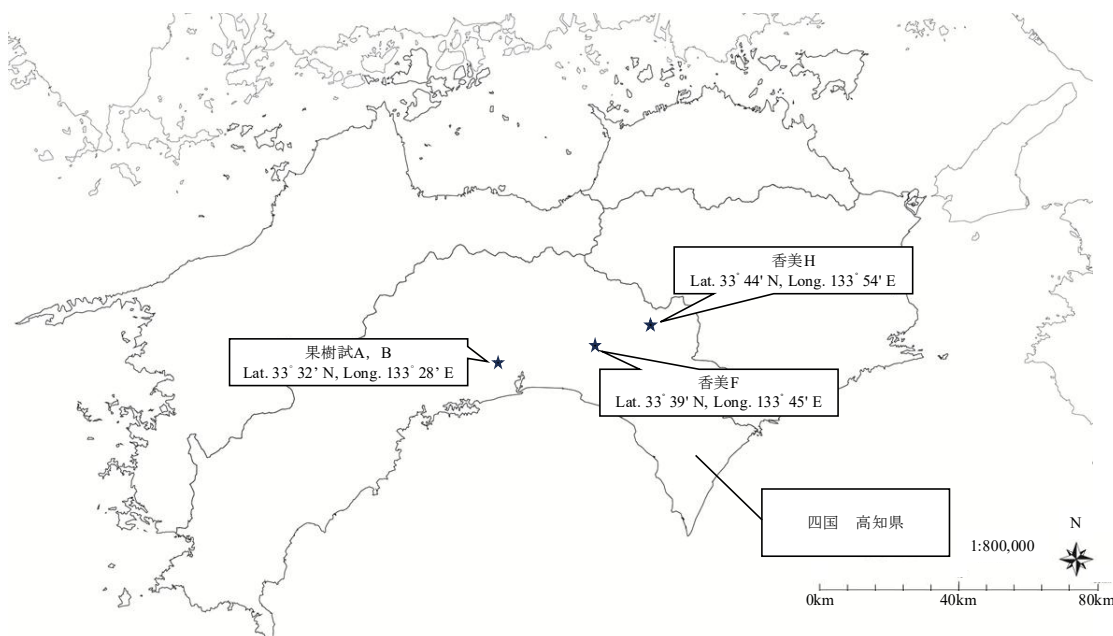


図4-1 調査園地の位置

#### 4.2.2 データセットの構築

学習用データセットとして、2020 年と 2021 年の果樹試 A 園および 2020 年と 2022 年の果樹試 B 園の画像を用いた。各画像は、GIMP を用いて 1 枚毎に樹体中心部から 1200×1200 pixel の範囲で切り出し、JPEG ファイル形式で保存した後(図 4-2)、アノテーションソフトウェアの labelImg を使用し、各画像内の果実に対してアノテーションを実施した。本章では、3 種類の YOLO モデル(YOLOv8m, YOLOv9c および YOLOv5mu) の果実検出性能を異なる学習条件で比較するために、3 種類の学習用データセットを構築した。図 4-3 に、モデル学習に用いたデータセットの構築方法を示す。図 4-3-a に示すデータセットでは、各園および各年のデータを無作為に 5 分割し、それらを組み合わせて 1 セット当たり 25 画像のデータセット(以下、25 画像データセット)を作成した。これらデータセットに、段階的に Contrast Change 0.5, Contrast Change 1.5 および Vertical Flip のデータ拡張(Data Augmentation)画像を加え(図 4-4, 以下、50 画像データセット, 75 画像データセット, 100 画像データセット)、それぞれをモデル学習に使用した。なお、オリジナル画像を全て含むデータセット(以下、125 画像データセット)については、モデル性能の妥当性を評価するために  $k$ -fold 交差検証を実施した。 $k$ -fold 交差検証はデータを  $k$  個のサブセットに分割し、各サブセットのうち  $k-1$  個のサブセットをモデル学習に使用し、残りのサブセットをモデル検証に使用する。これを  $k$  回繰り返す手法である。本章では、5-fold 交差検証を実施し、各評価指標の平均値を算出した。125 画像データセット以外のデータセットについては、5 分割したデータセットの

それぞれをモデル学習に使用し、各評価指標の平均値を算出した。図 4-3-b に示すデータセットでは、各園および各年のデータに Contrast Change 0.5, Contrast Change 1.5 および Vertical Flip のデータ拡張画像を加え、各園および各年単位のデータセットをモデル学習に使用した。ここでは、5-fold 交差検証を用いた。図 4-3-c に示すデータセットでは、晴天時に撮影した 2020 年の果樹試 B 園の 20 枚の画像について、Contrast Change 0.5, Contrast Change 1.5, Vertical Flip および Horizontal Flip のデータ拡張画像を加え、100 枚に増やした。その後、各園および各年のデータを無作為に 5 分割し、それらを組み合わせて 1 セット当たり 41 画像のデータセットを作成し、モデル学習に使用した。ここでも、5-fold 交差検証を用いた。表 4-2 に、各データセットにおける画像数と平均インスタンス数を示す。インスタンス数に基づく比率について、段階的にデータ拡張画像を加えたデータセットでは Train : Validation = 77.5 : 22.5、その他のデータセットでは Train : Validation = 80.0 : 20.0 であった。

Yuan (2023) の報告を参考に学習モデルを評価するために、検証用データセットとして、2022 年果樹試 A 園, 2021 年果樹試 B 園, 2023 年香美 F 園および H 園の画像を用いた。各画像から画像処理ソフトの Fiji-ImageJ を用いて樹木のみを切り取り、2250×2250 pixel の黒画像に貼り付け、PNG ファイル形式で保存した(図 4-5)。この処理は、地面、雑草および影等の背景の複雑性を最小限にし、果実のみに着目してモデル学習させるために行った。これらの画像について、labelImg を用いて各画像内の果実に対してアノテーションを実施した。



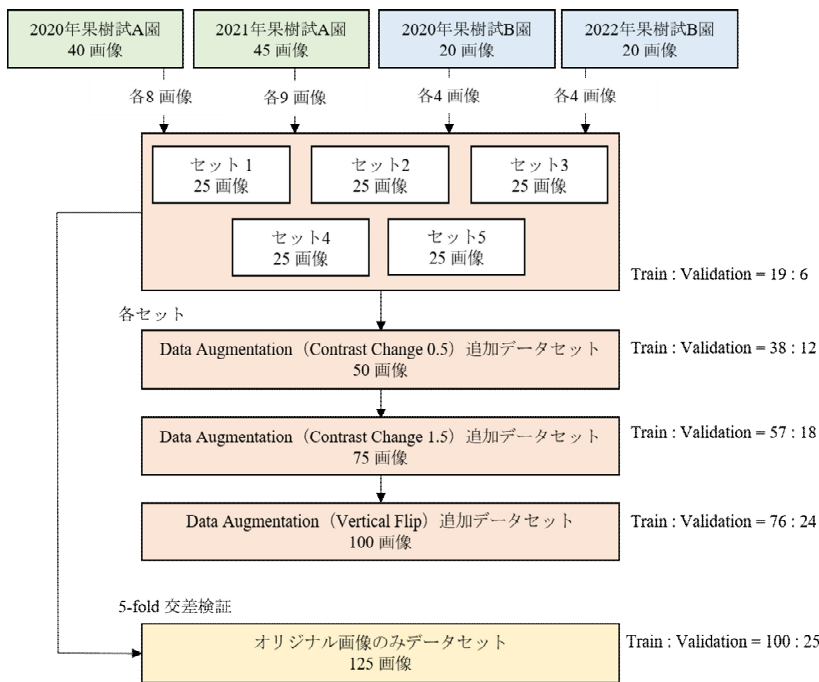
(a) 2020 年果樹試 A 園

(b) 2021 年果樹試 A 園

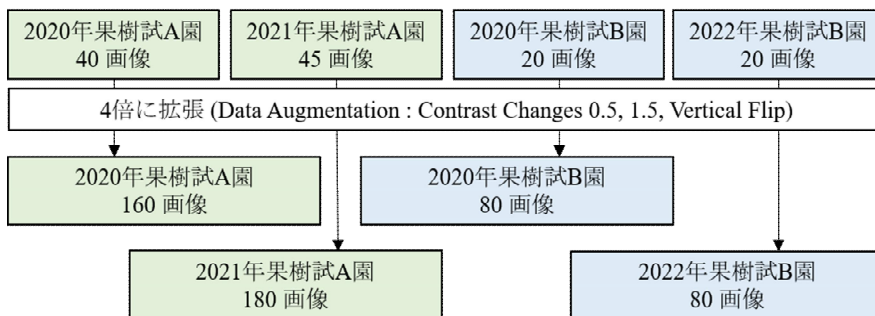
(c) 2020 年果樹試 B 園

(d) 2022 年果樹試 B 園

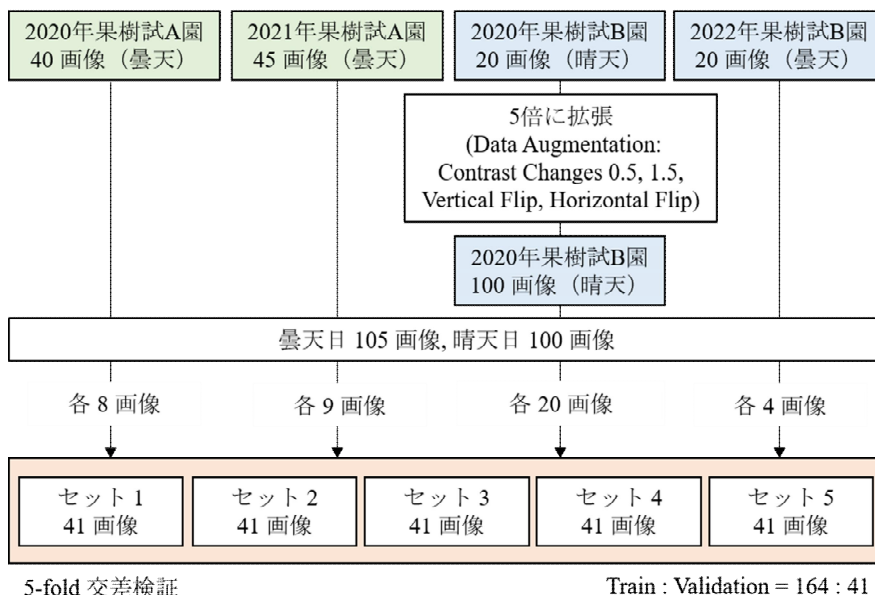
図 4-2 モデル学習に用いた画像



(a) データ拡張によって段階的に画像を増やしたデータセットの構築方法



(b) 園地毎のデータセットの構築方法



5-fold 交差検証

Train : Validation = 164 : 41

(c) 曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットの構築方法

図 4-3 モデル学習に用いたデータセットの構築方法



(a)オリジナル画像 (b)Contrast Change 0.5 (c)Contrast Change 1.5 (d)Vertical Flip

図4-4 モデル学習に用いたデータ拡張方法

表4-2 各データセットの画像数および平均インスタンス数

(a)データ拡張によって段階的に画像を増やしたデータセット


| データセット       | 画像数   |            |     | 平均インスタンス数 |            |       |
|--------------|-------|------------|-----|-----------|------------|-------|
|              | Train | Validation | 合計  | Train     | Validation | 合計    |
| 125 画像データセット | 100   | 25         | 125 | 9738      | 2434       | 12172 |
| 25 画像データセット  | 19    | 6          | 25  | 1887      | 547        | 2434  |
| 50 画像データセット  | 38    | 12         | 50  | 3774      | 1095       | 4869  |
| 75 画像データセット  | 57    | 18         | 75  | 5661      | 1642       | 7303  |
| 100 画像データセット | 76    | 24         | 100 | 7548      | 2190       | 9738  |

(b)園地毎のデータセット

| データセット       | 画像数   |            |     | 平均インスタンス数 |            |       |
|--------------|-------|------------|-----|-----------|------------|-------|
|              | Train | Validation | 合計  | Train     | Validation | 合計    |
| 2020 年 果樹試A園 | 128   | 32         | 160 | 10819     | 2705       | 13524 |
| 2021 年 果樹試A園 | 144   | 36         | 180 | 20000     | 5000       | 25000 |
| 2020 年 果樹試B園 | 64    | 16         | 80  | 3510      | 878        | 4388  |
| 2020 年 果樹試B園 | 64    | 16         | 80  | 4621      | 1155       | 5776  |

(c)曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセット

| データセット         | 画像数   |            |     | 平均インスタンス数 |            |       |
|----------------|-------|------------|-----|-----------|------------|-------|
|                | Train | Validation | 合計  | Train     | Validation | 合計    |
| 曇天画像と晴天画像がほぼ同数 | 164   | 41         | 205 | 13248     | 3312       | 16560 |



(a)2022年果樹試A園 (b)2021年果樹試B園 (c)2023年香美F園 (d)2023年香美H園

図4-5 モデル検証に用いた画像

#### 4.2.3 学習の実行環境

全てのモデル学習および検証は, Google (Google LLC, Mountain View, CA, USA) が提供するオンラインプラットフォームである Google Colaboratory (Colab) 上で, T4 GPU を使用して実行した。

#### 4.2.4 YOLOv8, YOLOv9 および YOLOv5u の概要

モデル学習には, YOLO シリーズの YOLOv8, YOLOv9 および YOLOv5u を使用した。YOLOv8 は 2023 年にリリースされた YOLO シリーズの 1 つである。特徴抽出と物体検出の性能を向上させるために, 最先端の Backbone と Neck Architecture を導入しており, Anchor-free Split Ultralytics Head の採用により, 高精度で効率的な検出が可能となっている。また, YOLOv8 はさまざまなタスクに対応するために, Inference, Validation, Training および Export 等のモードにより, 異なるニーズを持つユーザーへの対応が可能となっている (Ultralytics YOLOv8, <<https://docs.ultralytics.com/models/yolov8/>>, 2025 年 2 月 16 日参照, Jocher et al. 2023)。YOLOv9 は, 2024 年にリリースされた YOLO シリーズの 1 つである。Programmable Gradient Information (PGI) の概念と Generalized Efficient Layer Aggregation Network (GELAN) の高度なアーキテクチャを採用している。PGI の統合により, より深いネットワーク層への主要情報の転送が可能になり, 検出精度が向上している。GELAN は各層からの情報を効率的に集約し利用することで, モデル性能を向上させながら計算コストを削減する。これらにより, 限られたリソースでも高性能を実現する (Ultralytics YOLOv9, <<https://docs.ultralytics.com/models/yolov9/>>, 2025 年 2 月 16 日参照, Wang et al. 2024)。YOLOv5u は, 標準的な YOLOv5 モデルよりも高精度を実現するために設計された改良版である。YOLOv8 で採用された Anchor-free Split Ultralytics Head を導入することで, 物体検出における精度と速度のトレードオフを改善している (Ultralytics YOLOv5, <<https://docs.ultralytics.com/models/yolov5/>>, 2025 年 2 月 16 日参照, Jocher et al. 2020)。本章では, Common Objects in Context (COCO) データセットで学習した場合にモデルのパラメータが類似する, YOLOv8m, YOLOv9c および YOLOv5mu を比較検討した。

#### 4.2.5 モデル学習の実行

YOLOv8m, YOLOv9c および YOLOv5mu を用いて, 表 4-3 に示す Hyperparameter によりモデル学習を実行した。

表 4-3 モデル学習における Hyperparameter

| モデル                                    | YOLOv8m | YOLOv9c | YOLOv5mu |
|--|---------|---------|----------|
| Parameters<br>(Millions) <sup>2)</sup> | 25.8    | 25.3    | 25.0     |
| GFLOPs <sup>2)</sup>                   | 78.7    | 102.3   | 64.0     |
| Epochs                                 | 400     | 400     | 400      |
| Early Stopping                         | 50      | 50      | 50       |
| Batch Size                             | 8       | 8       | 8        |
| Image Size                             | 640×640 | 640×640 | 640×640  |
| Optimizer                              | AdamW   | AdamW   | AdamW    |
| Learning Rate                          | 0.002   | 0.002   | 0.002    |
| Momentum                               | 0.9     | 0.9     | 0.9      |

2) COCO データセットによる結果

#### 4.2.6 評価指標

本章では, 学習モデルの性能を評価するための評価指標として, precision (適合度), recall (再現度),  $F_1$ -score および Average Precision (以下, AP) を用いた。

precision は, 学習モデルが正予測したものの正確性を評価する。全ての正予測 (True Positive (TP) + False Positive (FP)) に対する真の正予測 (TP) の比率として定義する (式(4-1))。

$$\text{precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (4-1)$$

ここで TP は True Positive, FP は False Positive を示す。

recall は, 学習モデルが真の正予測をどれだけ取りこぼしなく予測できたかを評価する。実際の陽性事例 (TP + False Negative (FN)) に対する TP の比率として定義する (式(4-2))。recall が高ければ, 学習モデルが実際の陽性事例を適切に捉えていることを示す。

$$\text{recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (4-2)$$

ここで FN は False Negative を示す。

$F_1$ -score は, precision と recall の調和平均であり両指標のバランスを評価する (式(4-3))。  $F_1$ -score は 1 で最も高く, 0 で最も低くなる。

$$F_1\text{-score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (4-3)$$

AP は, precision を縦軸, recall を横軸とした precision-recall 曲線の下部面積 (AUC, Area Under Curve) で算出する (式

(4-4). この指標は, 学習モデルがどれだけ一貫して正確に予測できるかを評価する. APが高いほど, FP率を低く抑えながらTPを識別する性能が優れていることを示す. 本章では, 正解の Bounding Box と予測の Bounding Box の重なりが 50 %以上であった時に正予測したとし (IoU (Intersection over Union) = 50), この時の AP を算出した (以下, AP@50).

$$\text{Average Precision (AP)} = \int_0^1 P(R) dR \quad (4-4)$$

#### 4.2.7 構築した学習モデルの評価

構築した学習モデルは, 表 4-4 に示す Hyperparameter により検証を行った.

表 4-4 モデル検証における Hyperparameter

| モデル              | YOLOv8m   | YOLOv9c   | YOLOv5mu  |
|------------------|-----------|-----------|-----------|
| Batch Size       | 8         | 8         | 8         |
| Image Size       | 1200×1200 | 1200×1200 | 1200×1200 |
| Confidence Score | 0.25      | 0.25      | 0.25      |
| IoU              | 0.50      | 0.50      | 0.50      |

### 4.3 結果および考察

#### 4.3.1 データ拡張によりデータセットの画像数を違えた学習モデルの比較

表 4-5 に, データ拡張によりデータセットの画像数を違えた学習モデルの性能を示す. オリジナル画像全てを含む 125 画像データセット学習モデルは, 3 つの YOLO モデルの全ての評価指標が, 他のデータセットの学習モデルと比較して値が高かった. そのうち, YOLOv9c モデルの precision が 87.7 %, recall が 80.0 %, *F*-score が 83.6 % および AP@50 が 89.0 % と, YOLOv8m および YOLOv5mu モデルと比較して高かった. データ拡張画像を含まない 25 画像データセット学習モデルは, YOLOv5mu モデルの precision が 84.7 %, recall が 74.6 %, *F*-score が 79.3 % および AP@50 が 85.1 % と, 3 つの YOLO モデルの中で最も値が高かった. 25 画像データセットに Contrast Change 0.5 のデータ拡張画像を追加した 50 画像データセット学習モデルは, 3 つの YOLO モデルの全ての評価指標が, 25 画像データセット学習モデルと比較して値が高くなった. そのうち, YOLOv8m と YOLOv9c モデルの各評価指標値は, YOLOv5mu モデルと比較して 25 画像データセット学習モデルからの値の上昇率が高かった. 50 画像データセットに Contrast Change 1.5 のデータ拡張画像を追加した 75 画像データセット学習モデルは, YOLOv8m モデルの recall を除く 3 つの YOLO モデルの全ての評価指標値が 50 画像データセット学習モデルと同じか低くなった. 75 画

像データセットに Vertical Flip のデータ拡張画像を追加した 100 画像データセット学習モデルは, YOLOv8m モデルの precision を除く 3 つの YOLO モデル全ての評価指標値が 75 画像データセット学習モデルより高くなった. 100 画像データセット学習モデルは, YOLOv9c モデルの precision が 86.7 %, *F*-score が 81.7 % および AP@50 が 87.4 % と, YOLOv5mu および YOLOv8m モデルと比較して高かった.

表 4-6 に, データ拡張によりデータセットの画像数を違えた学習モデルの汎化性能を示す. オリジナル画像全てを含む 125 画像データセット学習モデルの AP@50 は, 2023 年香美 F 園の YOLOv8m を除く全ての検証用データセットにおいて, 最も高かった. そのうち, YOLOv9c が 2022 年果樹試 A 園で 88.7 %, 2021 年果樹試 B 園で 87.6 %, 2023 年香美 F 園で 81.5 % および 2023 年香美 H 園で 84.2 % と, YOLOv8m および YOLOv5mu モデルと比較して高かった. 25 画像データセット学習モデルの AP@50 は, YOLOv5mu モデルが 2022 年果樹試 A 園で 86.1 %, 2021 年果樹試 B 園で 84.9 %, 2023 年香美 F 園で 77.8 % および 2023 年香美 H 園で 79.5 % と, 3 つの YOLO モデルの中で最も高かった. 50 画像データセット学習モデルの AP@50 は, YOLOv8m が 2022 年果樹試 A 園で 86.2 %, 2023 年香美 F 園で 79.1 % および 2023 年香美 H 園で 81.3 % と最も高かった. 75 画像データセットの学習モデルの AP@50 は, YOLOv8m モデルの 2021 年果樹試 B 園, YOLOv9c および YOLOv5mu モデルの 2023 年香美 F 園を除く 3 つの YOLO モデルの全ての検証用データセットにおいて, 50 画像データセット学習モデルと同じか低かった. 100 画像データセット学習モデルの AP@50 は, 3 つの YOLO モデルの全ての検証用データセットにおいて, 75 画像データセット学習モデルより高かった.

データ拡張の種類と組み合わせが物体検出の性能に与える影響について, Shijie et al. (2017) はデータ拡張方法の組み合わせが画像分類に与える影響について報告しており, Cropping, Flipping, Wasserstein GAN および Rotation が, 他のデータ拡張方法よりも優れた性能向上をもたらすことを明らかにしている. また, その傾向は小規模なデータセットでより顕著であることを明らかにし, さらに, データ拡張方法の組み合わせにより性能が向上あるいは悪化する場合があると報告している. Alin et al. (2023) は, YOLOv5 モデルを使用した UAV の検出について複数の種類のデータ拡張方法を検討し, Mosaic が他の拡張方法と比較して最大の precision-recall 値を示したと報告している. また Fu et al. (2024) は, 緑色果実の検出のために開発された YOLOv5-AT モデルにおいて, 学習用データセットの画像数が少なくなるにつれ学習モデルの mAP が低下するが, データ拡張画像を組み込むことにより同数の学習用データセット画像でもモデルの検出性能が改

善することを報告している。本章のユズの果実検出においても、特にYOLOv8mとYOLOv9cの50画像データセット学習モデルは、25画像データセット学習モデルと比較して検出性能が大幅に向上した。一方、50画像データセット学習モデルと75画像データセット学習モデルの結果から、同類のデータ拡張方法の組み合わせ(Contrast Change 0.5および1.5)では検出性能はほとんど変化せず、75画像データセット学習モデルと100画像データセット学習モデルの結果から、Contrast Changeとは異なる種類のデータ拡張方法であるVertical Flip画像を加えると、全てのYOLOモデルで検出性能が再び向上した。したがって、異なる種類のデータ拡張方法を組み合わせることは、

本章が対象とするユズのUAV画像からの果実検出の性能向上にも有効であると考えられた。また、データ拡張による性能向上は、YOLOv8mおよびYOLOv9cモデルで高いことが明らかとなった。YOLOv8mとYOLOv9cの25画像データセット学習モデルにおいてYOLOv5muモデルよりも検出性能が低い理由として、学習用データセットの画像数が少なすぎるために生じる過学習の可能性が考えられた。また、50画像データセット学習モデルにおいて物体検出性能の向上が見られた理由として、データ拡張によって学習データセットの画像数が増えたことにより、YOLOv8mおよびYOLOv9cモデルが本来持つ特徴抽出能力を十分に発揮できるようになったためだと考えられた。

表 4-5 データ拡張によりデータセットの画像数を違えた学習モデルの比較

|          |                     | precision |                           |        |                           |        |                  |        |             |        |  |
|----------|---------------------|-----------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|--|
| モデル      | 25 画像 <sup>z)</sup> |           | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |  |
|          | オリジナル画像5分割          |           | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |  |
| YOLOv8m  | 78.6%               | ± 11.0%   | 86.7%                     | ± 2.3% | 85.4%                     | ± 2.0% | 85.0%            | ± 1.6% | 87.6%       | ± 1.4% |  |
| YOLOv9c  | 80.9%               | ± 17.0%   | 85.5%                     | ± 3.7% | 84.5%                     | ± 2.9% | 86.7%            | ± 1.6% | 87.7%       | ± 1.3% |  |
| YOLOv5mu | 84.7%               | ± 1.6%    | 85.3%                     | ± 1.3% | 85.3%                     | ± 2.3% | 85.9%            | ± 1.5% | 86.7%       | ± 1.6% |  |

|          |            | recall |                           |        |                           |        |                  |        |             |        |  |
|----------|------------|--------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|--|
| モデル      | 25 画像      |        | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |  |
|          | オリジナル画像5分割 |        | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |  |
| YOLOv8m  | 72.3%      | ± 7.4% | 73.4%                     | ± 2.2% | 73.6%                     | ± 3.5% | 76.0%            | ± 3.5% | 78.1%       | ± 2.0% |  |
| YOLOv9c  | 73.5%      | ± 5.6% | 75.9%                     | ± 2.2% | 75.3%                     | ± 4.9% | 77.4%            | ± 4.6% | 80.0%       | ± 1.6% |  |
| YOLOv5mu | 74.6%      | ± 4.3% | 76.2%                     | ± 4.8% | 74.9%                     | ± 3.4% | 77.5%            | ± 5.0% | 79.0%       | ± 0.9% |  |

|          |            | F <sub>r</sub> -score |                           |        |                           |        |                  |        |             |        |  |
|----------|------------|-----------------------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|--|
| モデル      | 25 画像      |                       | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |  |
|          | オリジナル画像5分割 |                       | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |  |
| YOLOv8m  | 75.2%      | ± 8.7%                | 79.5%                     | ± 2.1% | 79.0%                     | ± 2.4% | 80.2%            | ± 2.3% | 82.6%       | ± 1.5% |  |
| YOLOv9c  | 76.7%      | ± 11.3%               | 80.4%                     | ± 2.5% | 79.6%                     | ± 3.1% | 81.7%            | ± 2.8% | 83.6%       | ± 1.0% |  |
| YOLOv5mu | 79.3%      | ± 2.4%                | 80.4%                     | ± 3.0% | 79.7%                     | ± 2.3% | 81.4%            | ± 2.7% | 82.7%       | ± 1.0% |  |

|          |            | AP@50   |                           |        |                           |        |                  |        |             |        |  |
|----------|------------|---------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|--|
| モデル      | 25 画像      |         | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |  |
|          | オリジナル画像5分割 |         | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |  |
| YOLOv8m  | 80.3%      | ± 9.3%  | 84.8%                     | ± 2.3% | 84.7%                     | ± 3.1% | 85.4%            | ± 2.4% | 88.0%       | ± 1.1% |  |
| YOLOv9c  | 81.6%      | ± 12.7% | 85.7%                     | ± 2.1% | 85.2%                     | ± 2.9% | 87.4%            | ± 2.9% | 89.0%       | ± 0.9% |  |
| YOLOv5mu | 85.1%      | ± 2.5%  | 85.9%                     | ± 3.1% | 85.2%                     | ± 2.4% | 86.7%            | ± 3.0% | 88.0%       | ± 1.0% |  |

z) 値は平均±標準偏差を示す。

表 4-6 データ拡張によりデータセットの画像数を違えた学習モデルの汎化性能

(a) 2022 年 果樹試 A 園の検証用データセット

| モデル      | AP@50               |        |                           |        |                           |        |                  |        |             |        |
|----------|---------------------|--------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|
|          | 25 画像 <sup>z)</sup> |        | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |
|          | オリジナル画像 5 分割        |        | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |
| YOLOv8m  | 83.9%               | ± 4.7% | 86.2%                     | ± 1.0% | 85.8%                     | ± 0.6% | 86.8%            | ± 0.4% | 88.5%       | ± 0.5% |
| YOLOv9c  | 84.4%               | ± 4.9% | 86.2%                     | ± 1.0% | 85.4%                     | ± 1.5% | 86.8%            | ± 0.8% | 88.7%       | ± 0.3% |
| YOLOv5mu | 86.1%               | ± 0.8% | 86.0%                     | ± 1.0% | 85.8%                     | ± 0.6% | 87.3%            | ± 0.3% | 88.2%       | ± 0.7% |

(b) 2021 年 果樹試 B 園の検証用データセット

| モデル      | AP@50        |        |                           |        |                           |        |                  |        |             |        |
|----------|--------------|--------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|
|          | 25 画像        |        | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |
|          | オリジナル画像 5 分割 |        | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |
| YOLOv8m  | 81.1%        | ± 8.6% | 84.4%                     | ± 0.8% | 84.7%                     | ± 1.4% | 85.2%            | ± 0.7% | 87.6%       | ± 0.7% |
| YOLOv9c  | 81.8%        | ± 7.3% | 85.1%                     | ± 1.3% | 85.0%                     | ± 1.9% | 85.6%            | ± 1.0% | 87.6%       | ± 0.3% |
| YOLOv5mu | 84.9%        | ± 1.1% | 85.1%                     | ± 1.5% | 84.5%                     | ± 0.8% | 85.8%            | ± 1.0% | 87.4%       | ± 0.3% |

(c) 2023 年 香美 F 園の検証用データセット

| モデル      | AP@50        |         |                           |        |                           |        |                  |        |             |        |
|----------|--------------|---------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|
|          | 25 画像        |         | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |
|          | オリジナル画像 5 分割 |         | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |
| YOLOv8m  | 71.1%        | ± 11.6% | 79.1%                     | ± 2.4% | 77.5%                     | ± 2.4% | 80.8%            | ± 2.4% | 80.0%       | ± 1.0% |
| YOLOv9c  | 74.0%        | ± 7.5%  | 77.7%                     | ± 1.2% | 78.0%                     | ± 3.1% | 78.7%            | ± 1.6% | 81.5%       | ± 1.3% |
| YOLOv5mu | 77.8%        | ± 3.5%  | 78.0%                     | ± 3.0% | 79.7%                     | ± 2.1% | 80.2%            | ± 2.4% | 80.9%       | ± 2.2% |

(d) 2023 年 香美 H 園の検証用データセット

| モデル      | AP@50        |        |                           |        |                           |        |                  |        |             |        |
|----------|--------------|--------|---------------------------|--------|---------------------------|--------|------------------|--------|-------------|--------|
|          | 25 画像        |        | 50 画像                     |        | 75 画像                     |        | 100 画像           |        | 125 画像      |        |
|          | オリジナル画像 5 分割 |        | Contrast Change 0.5<br>追加 |        | Contrast Change 1.5<br>追加 |        | Vertical Flip 追加 |        | オリジナル画像全て含む |        |
| YOLOv8m  | 76.5%        | ± 9.1% | 81.3%                     | ± 1.6% | 80.2%                     | ± 1.7% | 81.9%            | ± 1.4% | 83.2%       | ± 1.5% |
| YOLOv9c  | 77.0%        | ± 6.1% | 80.2%                     | ± 1.8% | 79.7%                     | ± 2.3% | 80.6%            | ± 0.8% | 84.2%       | ± 1.2% |
| YOLOv5mu | 79.5%        | ± 1.8% | 80.4%                     | ± 2.0% | 80.3%                     | ± 1.5% | 81.4%            | ± 1.2% | 82.2%       | ± 2.8% |

z) 値は平均±標準偏差を示す。

#### 4.3.2 園地毎のデータセットを用いた学習モデルの比較

表 4-7 に、園地毎のデータセットを用いた学習モデルの比較を示す。2020 年果樹試 A 園データセット学習モデルは、125 画像データセット学習モデルと比較して、3 つの YOLO モデルの全ての指標が同等または高かったのに対し、他のデータセット学習モデルは同等または低くなった。

表 4-8 に、園地毎のデータセットを用いた学習モデルの汎化性能を示す。2022 年果樹試 A 園(曇天時に撮影)および 2021 年果樹試 B 園の検証用データセット(曇天時に撮影)では、2020 年果樹試 B 園データセット(晴天時に撮影)学習モデルが、他のデータセット学習モデルよりも AP@50 が低かった。2023 年香美 F

園データセット(未着色果実を撮影)および 2023 年香美 H 園検証用データセット(未着色果実を撮影)では、ほぼ全ての YOLO モデル(完全着色果実を撮影)で、125 画像データセット学習モデルよりも AP@50 が同等か低かった。YOLO モデル間で検出性能に一貫した傾向は見られなかった。

Mirhaji et al. (2021) はオレンジにおいて、曇天、晴天および 72 W の LED ライトを使用した夜間の画像を用いて YOLOv2, YOLOv3 および YOLOv4 の果実検出モデルを構築し、その検出性能が高かったと報告している。また Xu et al. (2023) は、YOLOv4 へ軽量特徴抽出ネットワークの GhostNet を適用した HPL-YOLOv4 を用いて構築したカンキツ類の果実検出モデルの検出

性能が、枝葉の遮蔽や光条件および画像のぼやけがあった場合でも YOLOv3 および YOLOv4 と比較して高かったと報告している。本章ではあえて、撮影条件(曇天および晴天)が偏った園地毎のデータセットを用いて学習モデルを構築した。いずれの YOLO モデルにおいても一定の検出性能はあったものの、学習用データセットと検出用データセットの撮影条件(曇天、晴

天)が一致しない場合は検出性能が下がる傾向であった。また、学習用データセットには含まれない未着色果実を含む検出用データセットでは、いずれの YOLO モデルにおいても検出性能は低かった。これらの結果より、撮影時の天候や果実着色等の学習用データセットの偏りが、果実検出モデルの性能に与える影響を明らかにした。

表 4-7 園地毎のデータセットを用いた学習モデルの比較

| モデル      | precision                            |                   |                   |                   |                   |
|----------|--------------------------------------|-------------------|-------------------|-------------------|-------------------|
|          | 125 画像 <sup>z)</sup><br>オリジナル画像を全て含む | 2020 年<br>果樹試 A 園 | 2021 年<br>果樹試 A 園 | 2020 年<br>果樹試 B 園 | 2022 年<br>果樹試 B 園 |
| YOLOv8m  | 87.6% ± 1.4%                         | 87.7% ± 1.5%      | 86.1% ± 1.9%      | 85.1% ± 2.3%      | 83.5% ± 2.4%      |
| YOLOv9c  | 87.7% ± 1.3%                         | 89.2% ± 1.1%      | 87.4% ± 1.4%      | 85.9% ± 3.1%      | 88.0% ± 3.7%      |
| YOLOv5mu | 86.7% ± 1.6%                         | 87.8% ± 1.5%      | 86.6% ± 1.5%      | 87.7% ± 3.5%      | 86.3% ± 5.3%      |
| モデル      | recall                               |                   |                   |                   |                   |
|          | 125 画像<br>オリジナル画像を全て含む               | 2020 年<br>果樹試 A 園 | 2021 年<br>果樹試 A 園 | 2020 年<br>果樹試 B 園 | 2022 年<br>果樹試 B 園 |
| YOLOv8m  | 78.1% ± 2.0%                         | 79.0% ± 1.6%      | 76.0% ± 2.5%      | 77.8% ± 2.8%      | 77.2% ± 5.2%      |
| YOLOv9c  | 80.0% ± 1.6%                         | 80.6% ± 1.6%      | 77.7% ± 3.5%      | 80.1% ± 3.0%      | 78.4% ± 3.3%      |
| YOLOv5mu | 79.0% ± 0.9%                         | 79.8% ± 1.8%      | 77.3% ± 2.6%      | 78.5% ± 3.6%      | 77.8% ± 2.8%      |
| モデル      | F <sub>1</sub> -score                |                   |                   |                   |                   |
|          | 125 画像<br>オリジナル画像を全て含む               | 2020 年<br>果樹試 A 園 | 2021 年<br>果樹試 A 園 | 2020 年<br>果樹試 B 園 | 2022 年<br>果樹試 B 園 |
| YOLOv8m  | 82.6% ± 1.5%                         | 83.1% ± 1.2%      | 81.9% ± 3.6%      | 81.3% ± 2.5%      | 80.1% ± 3.2%      |
| YOLOv9c  | 83.6% ± 1.0%                         | 84.7% ± 1.3%      | 82.2% ± 2.1%      | 82.9% ± 2.9%      | 82.9% ± 3.2%      |
| YOLOv5mu | 82.7% ± 1.0%                         | 83.6% ± 1.1%      | 81.7% ± 2.0%      | 82.8% ± 3.1%      | 81.8% ± 3.2%      |
| モデル      | AP@50                                |                   |                   |                   |                   |
|          | 125 画像<br>オリジナル画像を全て含む               | 2020 年<br>果樹試 A 園 | 2021 年<br>果樹試 A 園 | 2020 年<br>果樹試 B 園 | 2022 年<br>果樹試 B 園 |
| YOLOv8m  | 88.0% ± 1.1%                         | 88.2% ± 1.0%      | 86.6% ± 1.9%      | 86.1% ± 2.1%      | 85.9% ± 3.4%      |
| YOLOv9c  | 89.0% ± 0.9%                         | 89.2% ± 1.0%      | 87.7% ± 2.1%      | 87.5% ± 3.1%      | 87.6% ± 2.8%      |
| YOLOv5mu | 88.0% ± 1.0%                         | 88.6% ± 1.5%      | 87.1% ± 2.1%      | 87.1% ± 2.9%      | 87.0% ± 3.7%      |

z) 値は平均±標準偏差を示す。

表 4-8 園地毎のデータセットを用いた学習モデルの汎化性能

## (a) 2022 年 果樹試 A 園の検証用データセット

| モデル      | AP@50                |              |              |              |              |
|----------|----------------------|--------------|--------------|--------------|--------------|
|          | 125 画像 <sup>z)</sup> | 2020 年       | 2021 年       | 2020 年       | 2022 年       |
|          | オリジナル画像を全て含む         | 果樹試 A 園      | 果樹試 A 園      | 果樹試 B 園      | 果樹試 B 園      |
| YOLOv8m  | 88.5% ± 0.5%         | 86.8% ± 0.9% | 87.6% ± 0.6% | 83.3% ± 0.9% | 86.6% ± 0.4% |
| YOLOv9c  | 88.7% ± 0.3%         | 87.7% ± 0.8% | 87.9% ± 0.5% | 84.0% ± 1.2% | 87.6% ± 0.6% |
| YOLOv5mu | 88.2% ± 0.7%         | 86.5% ± 0.8% | 87.9% ± 0.5% | 84.3% ± 0.7% | 87.6% ± 0.6% |

## (b) 2021 年 果樹試 B 園の検証用データセット

| モデル      | AP@50        |              |              |              |              |
|----------|--------------|--------------|--------------|--------------|--------------|
|          | 125 画像       | 2020 年       | 2021 年       | 2020 年       | 2022 年       |
|          | オリジナル画像を全て含む | 果樹試 A 園      | 果樹試 A 園      | 果樹試 B 園      | 果樹試 B 園      |
| YOLOv8m  | 87.6% ± 0.7% | 85.8% ± 0.9% | 86.6% ± 0.4% | 82.7% ± 0.5% | 84.1% ± 1.0% |
| YOLOv9c  | 87.6% ± 0.3% | 86.9% ± 1.0% | 87.2% ± 0.7% | 82.4% ± 2.0% | 85.1% ± 0.8% |
| YOLOv5mu | 87.4% ± 0.3% | 85.7% ± 1.0% | 87.3% ± 0.6% | 83.4% ± 0.9% | 85.4% ± 0.7% |

## (c) 2023 年 香美 F 園の検証用データセット

| モデル      | AP@50        |              |              |              |              |
|----------|--------------|--------------|--------------|--------------|--------------|
|          | 125 画像       | 2020 年       | 2021 年       | 2020 年       | 2022 年       |
|          | オリジナル画像を全て含む | 果樹試 A 園      | 果樹試 A 園      | 果樹試 B 園      | 果樹試 B 園      |
| YOLOv8m  | 80.0% ± 1.0% | 74.6% ± 1.8% | 76.9% ± 1.3% | 78.5% ± 2.5% | 77.9% ± 1.5% |
| YOLOv9c  | 81.5% ± 1.3% | 77.4% ± 1.4% | 79.6% ± 1.6% | 77.8% ± 2.2% | 78.2% ± 2.5% |
| YOLOv5mu | 80.9% ± 2.2% | 75.5% ± 1.7% | 81.0% ± 0.5% | 80.8% ± 1.4% | 80.1% ± 1.2% |

## (d) 2023 年 香美 H 園の検証用データセット

| モデル      | AP@50                |              |              |              |              |
|----------|----------------------|--------------|--------------|--------------|--------------|
|          | 125 画像 <sup>z)</sup> | 2020 年       | 2021 年       | 2020 年       | 2022 年       |
|          | オリジナル画像を全て含む         | 果樹試 A 園      | 果樹試 A 園      | 果樹試 B 園      | 果樹試 B 園      |
| YOLOv8m  | 83.2% ± 1.5%         | 77.0% ± 1.4% | 77.4% ± 1.4% | 81.3% ± 0.5% | 80.0% ± 1.7% |
| YOLOv9c  | 84.2% ± 1.2%         | 76.9% ± 2.1% | 77.0% ± 2.0% | 82.4% ± 0.8% | 78.5% ± 2.2% |
| YOLOv5mu | 82.2% ± 2.8%         | 75.3% ± 2.3% | 79.5% ± 0.6% | 83.6% ± 0.3% | 78.6% ± 1.2% |

z) 値は平均±標準偏差を示す。

#### 4.3.3 曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの比較

表 4-9 に、曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの性能を示す。曇天画像と晴天画像がほぼ同数のデータセットの YOLOv9c および YOLOv5mu モデルは、125 画像データセット学習モデルよりもそれぞれ precision が 1.0 % および 0.9 % 高く、YOLOv8m モデルは、125 画像データセット学習モデルよりも recall が 1.0 % 高かった。一方で、 $F_1$ -score と AP@50 に大きな差は見られなかつ

た。

表 4-10 に、曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの汎化性能を示す。2023 年香美 F 園データセットについて、曇天画像と晴天画像がほぼ同数のデータセットの YOLOv8m モデルおよび YOLOv5mu モデルは、125 画像データセット学習モデルよりも AP@50 がそれぞれ 1.2 % および 1.6 % 高かった。2023 年香美 H 園データセットについて、曇天画像と晴天画像がほぼ同数のデータセットの YOLOv9c モデルは、125 画像データセット学習

モデルよりもAP@50が0.8%低かったのに対し、曇天画像と晴天画像がほぼ同数のデータセットのYOLOv5muモデルは、AP@50が1.9%高かった。

Buda et al. (2018)は、クラス不均衡が分類性能に負の影響を与えると報告している。本章の結果では、学習用データセットの撮影時の天候に偏りがあった場合でも、本章で検討した3つのYOLOモデルの検出性能は学習用データセットに偏りがな

い場合とほぼ同等であった。また、未着色果実を含む2023年香美F園およびH園検証用データセットにおいても、3つのYOLOモデルの検出性能は学習用データセットに偏りがない場合とほぼ同等であった。これらの結果から、本章が対象とするユズの果実検出において、学習用データセットに含む画像の撮影条件が不均衡であっても検出性能への影響は小さいが、着色程度は検出に与える影響が大きいと考えられた。

表 4-9 曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの比較

| モデル      | precision            |              | recall       |              |
|----------|----------------------|--------------|--------------|--------------|
|          | 125 画像 <sup>z)</sup> | 曇天画像と晴天画像    | 125 画像       | 曇天画像と晴天画像    |
|          | オリジナル画像全て含む          | がほぼ同数        | オリジナル画像全て含む  | がほぼ同数        |
| YOLOv8m  | 87.6% ± 1.4%         | 86.9% ± 1.5% | 78.1% ± 2.0% | 79.1% ± 1.6% |
| YOLOv9c  | 87.7% ± 1.3%         | 88.7% ± 0.9% | 80.0% ± 1.6% | 79.7% ± 1.4% |
| YOLOv5mu | 86.7% ± 1.6%         | 87.7% ± 2.1% | 79.0% ± 0.9% | 78.6% ± 0.8% |

| モデル      | F-score      |              | AP@50        |              |
|----------|--------------|--------------|--------------|--------------|
|          | 125 画像       | 曇天画像と晴天画像    | 125 画像       | 曇天画像と晴天画像    |
|          | オリジナル画像全て含む  | がほぼ同数        | オリジナル画像全て含む  | がほぼ同数        |
| YOLOv8m  | 82.6% ± 1.5% | 82.8% ± 1.5% | 88.0% ± 1.1% | 88.1% ± 1.4% |
| YOLOv9c  | 83.6% ± 1.0% | 84.0% ± 0.8% | 89.0% ± 0.9% | 89.1% ± 0.7% |
| YOLOv5mu | 82.7% ± 1.0% | 82.9% ± 0.8% | 88.0% ± 1.0% | 88.3% ± 0.6% |

z) 値は平均±標準偏差を示す。

表 4-10 曇天時の撮影画像と晴天時の撮影画像をほぼ同数としたデータセットを用いた学習モデルの汎化性能

| モデル      | 2022年 果樹試A園          |              | 2021年 果樹試B園  |              |
|----------|----------------------|--------------|--------------|--------------|
|          | 125 画像 <sup>z)</sup> | 曇天画像と晴天画像    | 125 画像       | 曇天画像と晴天画像    |
|          | オリジナル画像全て含む          | がほぼ同数        | オリジナル画像全て含む  | がほぼ同数        |
| YOLOv8m  | 88.5% ± 0.5%         | 87.9% ± 0.9% | 87.6% ± 0.7% | 87.1% ± 0.9% |
| YOLOv9c  | 88.7% ± 0.3%         | 88.3% ± 0.9% | 87.6% ± 0.3% | 87.4% ± 0.6% |
| YOLOv5mu | 88.2% ± 0.7%         | 88.4% ± 0.3% | 87.4% ± 0.3% | 87.4% ± 0.4% |

| モデル      | 2023年 果樹試F園  |              | 2023年 果樹試H園  |              |
|----------|--------------|--------------|--------------|--------------|
|          | 125 画像       | 曇天画像と晴天画像    | 125 画像       | 曇天画像と晴天画像    |
|          | オリジナル画像全て含む  | がほぼ同数        | オリジナル画像全て含む  | がほぼ同数        |
| YOLOv8m  | 80.0% ± 1.0% | 81.2% ± 1.5% | 83.2% ± 1.5% | 83.5% ± 1.8% |
| YOLOv9c  | 81.5% ± 1.3% | 81.4% ± 1.2% | 84.2% ± 1.2% | 83.4% ± 1.3% |
| YOLOv5mu | 80.9% ± 2.2% | 82.5% ± 0.5% | 82.2% ± 2.8% | 84.1% ± 1.0% |

z) 値は平均±標準偏差を示す。

以上より、ユズにおける空撮画像からの着果数推定に必要なデータ拡張手法を明らかにした。本章では、Contrast Change や Vertical Flip 等のデータ拡張手法を使用したモデルの検出性能を評価したが、いずれの評価指標においても値が90%に達しなかった。実用化のためには、空撮方法やPix2pix等の高度なデータ拡張手法の検討および果実の着色程度や枝葉等の遮蔽の影響を考慮したアノテーションを行い果実推定モデルを構築することにより、検出性能をより高める必要がある。

#### 4.4 参考文献

- 1) Alin, A. Y. and K. A. Yuana (2023) Data Augmentation Method on Drone Object Detection with YOLOv5 Algorithm, In 2023 Eighth International Conference on Informatics and Computing (ICIC), Manado, Indonesia, 1-6.
- 2) Buda, M., A. Maki and M. A. Mazurowski (2018) A Systematic Study of the Class Imbalance Problem in Convolutional Neural Networks, Neural Networks, 106:249-259.
- 3) Fu, X., S. Zhao, C. Wang, X. Tang, D. Tao, G. Li, L. Jiao and D. Dong (2024) Green Fruit Detection with a Small Dataset under a Similar Color Background Based on the Improved YOLOv5-AT, Foods, 13(7):1060.
- 4) Jocher, G., A. Chaurasia and J. Qiu (2023) YOLO by Ultralytics; Version 8.0.0, <<https://github.com/ultralytics/ultralytics>>, 2025年2月16日参照.
- 5) Jocher, G. (2020) Ultralytics YOLOv5, <<https://github.com/ultralytics/yolov5>>, 2025年2月16日参照.
- 6) Mirhaji, H., M. Soleymani, A. Asakereh and S. A. Mehdizadeh (2021) Fruit Detection and Load Estimation of an Orange Orchard Using the YOLO Models Through Simple Approaches in Different Imaging and Illumination Conditions, Computers and Electronics in Agriculture, 191:106533.
- 7) Shijie, J., W. Ping, J. Peiyi and H. Siping (2017) Research on Data Augmentation for Image Classification Based on Convolution Neural Networks, In 2017 Chinese Automation Congress (CAC), Jinan, China, 4165-4170.
- 8) Wang, C. Y., I. H. Yeh and H. Y. M. Liao (2024) YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information, European Conference on Computer Vision, Cham, Springer Nature: Switzerland, 1-24.
- 9) Xu, L., Y. Wang, X. Shi, Z. Tang, X. Chen, Y. Wang, Z. Zou, P. Huang, B. Liu, N. Yang, Z. Lu, Y. He and Y. Zhao (2023) Real-Time and Accurate Detection of Citrus in Complex Scenes Based on HPL-YOLOv4, Computers and Electronics in Agriculture, 205:107590.
- 10) Yuan, W (2023) Accuracy Comparison of YOLOv7 and YOLOv4 Regarding Image Annotation Quality for Apple Flower Bud Classification, AgriEngineering, 5(1):413-424.

## 第5章 多項式回帰を用いたユズの果実階級比率予測モデルの構築

### 5.1 はじめに

本章では、ユズに焦点を当て、収穫直後に測定した果実の平均横径から果実階級比率を予測するモデルを構築し、さらに、構築モデルの精度と汎用性について、3年8園地で評価した。

### 5.2 材料および方法

#### 5.2.1 データセットの構築

データセットの構築には、場内の3つのユズ園(以下、果樹試A, B およびC園)および高知県香美市の5つの生産者園(以下、香美E, F, G, H およびI園)で取得したデータを用いた。表5-1

に調査園地の概要を、図5-1に調査園地の位置を示す。果樹試A, B およびC園ではそれぞれ全樹を調査し、香美E, F, G, H およびI園では「5.3.3 果実階級比率予測モデルに用いる樹数の検証」の結果に基づき、10樹を無作為に選り調査した。なお、ユズの慣行栽培方法に基づき、栽培期間中に摘果は実施しなかった。11月に1樹毎に全果実を収穫した後、デジタルノギスを用いて各果実の最長横径を測定し、あわせて果実階級を高知県農業協同組合が定めた基準(表5-2)に準じて分類した。樹毎の果実平均横径と階級比率を算出し、園毎にこれらの統合データセットを構築した。

表5-1 調査園地の概要

| 園地名  | 調査年  | 樹齢(年) | 樹数 | 着果数(果/樹) <sup>z)</sup> |
|------|------|-------|----|------------------------|
| 果樹試A | 2020 | 21~25 | 42 | 266.2 ± 174.1          |
| 果樹試A | 2021 | 22~26 | 47 | 452.5 ± 193.1          |
| 果樹試B | 2021 | 11~12 | 26 | 121.8 ± 68.5           |
| 果樹試C | 2022 | 20~21 | 31 | 129.5 ± 70.0           |
| 香美E  | 2023 | 15    | 10 | 195.1 ± 62.8           |
| 香美F  | 2023 | 10    | 10 | 119.5 ± 15.7           |
| 香美G  | 2023 | 15    | 10 | 130.8 ± 30.3           |
| 香美H  | 2023 | 9     | 10 | 303.3 ± 63.6           |
| 香美I  | 2023 | 40以上  | 10 | 116.2 ± 20.2           |

z) ±以後は標準偏差を示す。

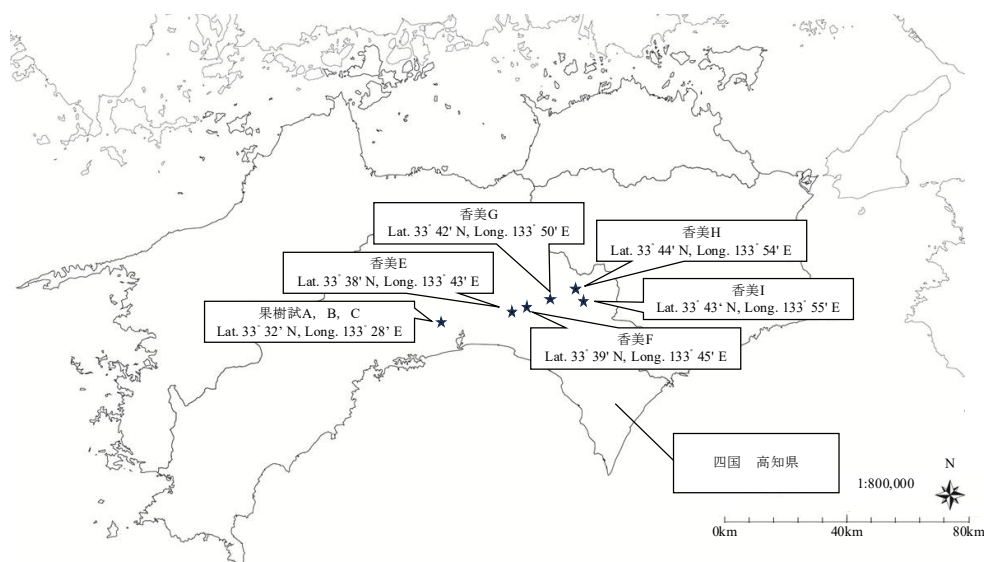


図5-1 調査園地の位置

表 5-2 ユズの果実階級規格

| 果実階級     | S 級       | M 級       | L 級       | 2L 級      | 3L 級      |
|----------|-----------|-----------|-----------|-----------|-----------|
| 果実横径(mm) | 50.0~60.0 | 60.0~65.0 | 65.0~75.0 | 75.0~85.0 | 85.0~96.0 |

注) 高知県農業協同組合が定めた基準に準じて作成。

### 5.2.2 果実階級比率予測モデルの構築

果実階級比率予測モデルを構築するために、2020 年の果樹試 A 園のデータセットを用いて多項式回帰分析を実施した。S, L, 2L および 3L の各階級の果実横径の階級間隔が 10.0 mm または 11.0 mm である一方、M 級の間隔は 5.0 mm であることから、M 級を予測するモデルとその他階級を予測するモデルを分け、それぞれ 2 つのモデルを構築した。各モデルの構築には、以下の調整を行った。

S, L, 2L および 3L 級の果実階級比率予測モデルの構築には、全ての階級比率を 2L 級と見なすための調整を行った。具体的には、各データの平均果実横径から 2L 級の中央値(80.0 mm)とその他階級の中央値(S 級:55 mm, M 級:62.5 mm, L 級:70 mm, 3L 級:90.5 mm)の差分を加算または減算し、補正平均果実横径を算出した。補正平均果実横径を独立変数、2L 級と見なした階級比率を従属変数として、補正平均果実横径 80.0 mm 以下のデータセットと 80.0 mm 以上のデータセットに分割して、それぞれ多項式回帰分析を行った。なお、階級比率が 0 % または明らかな外れ値を含むデータセットは除外した。

M 級の果実階級比率予測モデルの構築には、全ての階級比率を M 級と見なすための調整を行った。具体的にはまず、M 級以外の各階級のデータセットを中央値の前後で 2 分割した。ただ

し、3L 級については 90 mm 前後で分割した。前半のデータセットについて、各データの平均果実横径から M 級の中央値(62.5 mm)とその他階級の第一四分位数(S 級:52.5 mm, L 級:67.5 mm, 2L 級:77.5 mm, 3L 級:87.5 mm)の差分を加算または減算し、補正平均果実横径を算出した。後半のデータセットについて、各データの平均果実横径から M 級の中央値(62.5 mm)とその他階級の第三四分位数(S 級:57.5 mm, L 級:72.5 mm, 2L 級:82.5 mm, 3L 級:93.0 mm)の差分を加算または減算し、補正平均果実横径を算出した。補正平均果実横径を独立変数、M 級と見なした階級比率を従属変数として、補正平均果実横径 62.5 mm 以上のデータセットと 62.5 mm 未満のデータセットに分割して、それぞれ多項式回帰分析を行った。なお、階級比率が 0 % または明らかな外れ値を含むデータセットは除外した。

### 5.2.3 果実階級比率予測モデルの評価

「5.2.2 果実階級比率予測モデルの構築」で構築した果実階級比率予測モデル(表 5-3)の評価は、自由度修正済み決定係数(以下、 $R^2$ )および赤池情報量基準(以下、AIC)により行った。さらに、分散分析と Shapiro-Wilk 検定を実施し、モデルの正規性を正規 Q-Q プロットと残差プロットにより検証した。統計分析には、エクセル統計 4.07 を用いた。

表 5-3 ユズの果実階級比率予測モデル

| 予測階級           | 補正平均<br>果実横径(mm) | 予測式   |
|----------------|------------------|---|
| S, L, 2L, 3L 級 | 80.0 mm 未満       | $Y = 2415.22774353763 \times X - 54.3714958429455 \times X^2 + 0.540689486931215 \times X^3 - 0.00200155825488475 \times X^4 - 40023.9321918696$  |
|                | 80.0 mm 以上       | $Y = 2014.4101941173 \times X - 32.9240158460213 \times X^2 + 0.236928795292734 \times X^3 - 0.000634298285488405 \times X^4 - 45699.032851052$   |
| M 級            | 62.5 mm 未満       | $Y = 720.382777711563 \times X - 21.7490919448307 \times X^2 + 0.289164365791268 \times X^3 - 0.00142548123214497 \times X^4 - 8879.1156473058$   |
|                | 62.5 mm 以上       | $Y = 796.658609575696 \times X - 16.3869584980163 \times X^2 + 0.147988129657846 \times X^3 - 0.000496138110229293 \times X^4 - 14303.4362700805$ |

注 1) 予測したい階級の補正平均果実横径の条件に応じて予測式を選択。

2) 補正平均果実横径を予測式の X に入力。ただし、3L 級の算出には補正平均果実横径(X) = 平均果実横径 - 10.5, 2L 級および M 級の算出には X = 平均果実横径, L 級の算出には X = 平均果実横径 + 10, S 級の算出には X = 平均果実横径 + 25 を入力。

3) 予測値(Y)がマイナスとなった場合は 0 とする。

#### 5.2.4 果実階級比率予測モデルの検証

「5.2.2 果実階級比率予測モデルの構築」で構築した果実階級比率予測モデルの汎化性を評価するため、果樹試A, BおよびC園から取得した4つのデータセットを使用し、4つのデータセットより1つ, 2つまたは3つのデータセットをそれぞれ選択し、14の異なる果実階級比率予測モデルを構築した。なお、モデルの構築方法は、「5.2.2 果実階級比率予測モデルの構築」と同様の方法で行った。選択しなかった残りのデータセットを使用し、28回の検証を行った。モデルの精度は式(5-1)で定義したEMA (Estimation Model's Accuracy) とピアソンの $\chi^2$ 検定を用いて評価した。さらに、各園の果実横径のばらつきを、果実横径の経験的累積分布関数 (Empirical Cumulative Distribution Function) で比較した。

$$\text{EMA} (\%) = \sum |N_{\text{act}} - N_{\text{est}}| \quad (5-1)$$

ここで $N_{\text{act}}$ は各果実階級比率の実値、 $N_{\text{est}}$ は推定値を示す。

#### 5.2.5 果実階級比率予測モデルに用いる樹数の検証

「5.2.2 果実階級比率予測モデルの構築」で構築した果実階級比率予測モデルの精度を、果樹試A, BおよびC園から取得した3つのデータセットを使用して、樹数を違えて検証した。各園につき1樹, 5樹または10樹を無作為に選び、各樹の平均果実横径を構築したモデル(表5-3)に入力し、各樹の推定比率を算出した。推定比率に各樹の収穫果実数を乗じて、各階級の推定果数を算出した。園毎の推定比率は、各階級の推定果数を合計し算出した。実測比率も同様の方法で算出した。以上を100回繰り返した。各園の評価にはEMAを使用した。

#### 5.2.6 生産者園における果実階級比率予測モデルの検証

「5.2.2 果実階級比率予測モデルの構築」で構築した果実階級比率予測モデルの精度を、香美E, F, G, HおよびI園のデータセットにより検証した。各園の推定比率と実際比率は、「5.2.5 果実階級比率予測モデルに用いる樹数の検証」と同様の方法

で算出した。評価にはEMAとピアソンの $\chi^2$ 検定を用いた。

### 5.3 結果

#### 5.3.1 果実階級比率予測モデルの構築と評価

補正平均果実横径と2L級の階級比率の関係は、果実横径80.0 mm付近をピークとした非対称な分布を示し、ピークにおける最大階級比率は70.3%だった(図5-2-a)。平均果実横径80.0 mm未満のデータセットと80.0 mm以上のデータセットに分割して、それぞれ多項式回帰分析を行った結果、 $R^2$ は四次多項式および五次多項式がそれぞれ80.0 mm未満で0.98, 80.0 mm以上で0.99と最も高くなった。また、AICは四次多項式が80.0 mm未満で270.36, 80.0 mm以上で502.38と最も低くなった。それぞれの四次多項式に対して分散分析を実施した結果、いずれも5%水準で有意であった(表5-4)。80.0 mm以上の式はShapiro-Wilk検定において有意差は見られなかった(表5-4)が、正規Q-Qプロットでは特異な分布傾向が見られず(図5-3-a, b)、予測値と残差に基づく残差プロットでも一貫した傾向は見られなかった(図5-4-a, b)。

補正平均果実横径とM級の階級比率の関係は、果実横径62.5 mm付近をピークとした非対称な分布を示し、ピークにおける最大階級比率は約39.2%であった(図5-2-b)。果実横径62.5 mm未満のデータセットと62.5 mm以上のデータセットに分割して、それぞれ多項式回帰分析を行った結果、 $R^2$ は四次多項式および五次多項式がそれぞれ62.5 mm未満で0.96, 62.5 mm以上で0.96と最も高くなった。また、AICは62.5 mm未満で四次多項式が546.23, 62.5 mm以上で五次多項式が732.99と最も低くなった。しかし、いずれも四次多項式と五次多項式のAICの差が、三次多項式と四次多項式のAICの差より小さかった。四次多項式に対して分散分析を実施した結果、いずれも5%水準で有意であった(表5-4)。62.5 mm以上の式はShapiro-Wilk検定において有意差は見られなかった(表5-4)が、正規Q-Qプロットでは特異な分布傾向が見られず(図5-3-c, d)、予測値と残差に基づく残差プロットでも一貫した傾向は見られなかった(図5-4-c, d)。

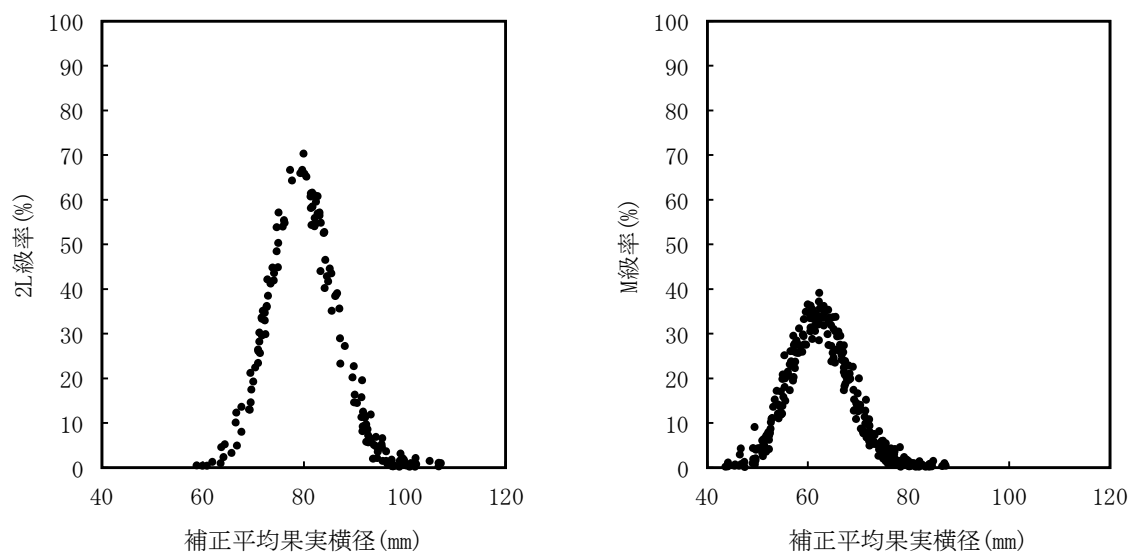



図 5-2 補正平均果実横径と果実階級比率の関係


表 5-4 多項式回帰式の適合性の評価および四次多項式の検定

| 予測階級 | 補正平均果実横径(mm) | データ数 | 評価指標  | 多項式の次数 |        |        |        | 四次多項式の検定   |             |
|------|--------------|------|-------|--------|--------|--------|--------|------------|-------------|
|      |              |      |       | 二次     | 三次     | 四次     | 五次     | F値         | W値          |
| 2L 級 | 80.0 mm 未満   | 54   | $R^2$ | 0.96   | 0.97   | 0.98   | 0.98   | 610.62 **  | 0.974 n. s. |
|      |              |      | AIC   | 312.02 | 288.65 | 270.36 | 272.32 |            |             |
| 2L 級 | 80.0 mm 以上   | 101  | $R^2$ | 0.98   | 0.98   | 0.99   | 0.99   | 1626.64 ** | 0.970 *     |
|      |              |      | AIC   | 531.38 | 533.20 | 502.38 | 503.87 |            |             |
| M 級  | 62.5 mm 未満   | 114  | $R^2$ | 0.92   | 0.95   | 0.96   | 0.96   | 718.50 **  | 0.984 n. s. |
|      |              |      | AIC   | 604.98 | 556.17 | 546.23 | 546.25 |            |             |
| M 級  | 62.5 mm 以上   | 166  | $R^2$ | 0.96   | 0.96   | 0.96   | 0.96   | 1159.15 ** | 0.980 *     |
|      |              |      | AIC   | 759.65 | 760.73 | 738.87 | 732.99 |            |             |


注) 分散分析または Shapiro-Wilk 検定により, \*\*は 1 %水準で, \*は 5 %水準で有意差あり, n. s. は有意差なし。




(a) 2L 級 (80.0 mm 未満) の四次多項式



(b) 2L 級 (80.0 mm 以上) の四次多項式




(c) M 級 (62.5 mm 未満) の四次多項式




(d) M 級 (62.5 mm 以上) の四次多項式


図 5-3 四次多項式の正規性確認のための残差を用いた正規 Q-Q プロット




(a) 2L 級 (80.0 mm 未満) の四次多項式



(b) 2L 級 (80.0 mm 以上) の四次多項式



(c) M 級 (62.5 mm 未満) の四次多項式



(d) M 級 (62.5 mm 以上) の四次多項式

図 5-4 四次多項式の正規性確認のための予測値を用いた残差プロット

5.3.2 果実階級比率予測モデルの検証

14の異なるデータセットを用いて構築した果実階級比率予測モデルにより検証を行った結果,EMAは2.0~6.1%と10.0%

以下であった.また,全ての検証において,ピアソンの $\chi^2$ 検定で有意差は見られなかった(表5-5).果実横径の経験累積分布関数は全園で標準正規分布に近似した(図5-5).

表5-5 異なるデータセットを用いて構築した果実階級比率予測モデルの検証

| 果実階級比率<br>予測モデル構築<br>に用いた<br>データセット | EMA           |               |      |      | p 値 <sup>z)</sup> |                |                |                |
|-------------------------------------|---------------|---------------|------|------|-------------------|----------------|----------------|----------------|
|                                     | 2020年<br>果樹試A | 2021年<br>果樹試A | 果樹試B | 果樹試C | 2020年<br>果樹試A     | 2021年<br>果樹試A  | 果樹試B           | 果樹試C           |
| 2020年果樹試A                           |               | 4.4%          | 5.5% | 2.2% |                   | 0.989<br>n. s. | 0.983<br>n. s. | 0.980<br>n. s. |
| 2021年果樹試A                           | 2.9%          |               | 4.0% | 5.5% | 0.998<br>n. s.    |                | 0.974<br>n. s. | 0.912<br>n. s. |
| 果樹試B                                | 2.0%          | 4.6%          |      | 2.5% | 0.999<br>n. s.    | 0.986<br>n. s. |                | 0.975<br>n. s. |
| 果樹試C                                | 3.0%          | 4.7%          | 6.1% |      | 0.981<br>n. s.    | 0.904<br>n. s. | 0.935<br>n. s. |                |
| 2020年果樹試A<br>+ 2021年果樹試A            |               |               | 4.4% | 4.2% |                   |                | 0.983<br>n. s. | 0.947<br>n. s. |
| 2021年果樹試A<br>+ 果樹試B                 | 2.7%          |               |      | 4.8% | 0.998<br>n. s.    |                |                | 0.930<br>n. s. |
| 果樹試B<br>+ 果樹試C                      | 2.5%          | 4.5%          |      |      | 0.995<br>n. s.    | 0.970<br>n. s. |                |                |
| 2020年果樹試A<br>+ 果樹試B                 |               | 4.3%          |      | 2.2% |                   | 0.989<br>n. s. |                | 0.979<br>n. s. |
| 2021年果樹試A<br>+ 果樹試C                 | 2.8%          |               | 4.6% |      | 0.997<br>n. s.    |                | 0.979<br>n. s. |                |
| 2020年果樹試A<br>+ 果樹試C                 |               | 4.3%          | 5.4% |      |                   | 0.980<br>n. s. | 0.982<br>n. s. |                |
| 2020年果樹試A<br>+ 2021年果樹試A<br>+ 果樹試B  |               |               |      | 3.9% |                   |                |                | 0.952<br>n. s. |
| 2020年果樹試A<br>+ 2021年果樹試A<br>+ 果樹試C  |               |               | 4.7% |      |                   |                | 0.984<br>n. s. |                |
| 2020年果樹試A<br>+ 果樹試B<br>+ 果樹試C       |               | 4.3%          |      |      |                   | 0.984<br>n. s. |                |                |
| 2021年果樹試A<br>+ 果樹試B<br>+ 果樹試C       | 2.7%          |               |      |      | 0.998<br>n. s.    |                |                |                |
| 最大値                                 | 2.0%          | 4.3%          | 4.0% | 2.2% | 0.981             | 0.904          | 0.935          | 0.912          |
| 最小値                                 | 3.0%          | 4.7%          | 6.1% | 5.5% | 0.999             | 0.989          | 0.984          | 0.980          |

z) ピアソンの $\chi^2$ 検定により,n. s.は有意差なし.





図 5-5 各園の果実横径の経験的累積分布関数


### 5.3.3 果実階級比率予測モデルに用いる樹数の検証

果樹試A, BおよびC園の全樹でそれぞれ算出したEMAは, 果樹試A, BおよびC園でそれぞれ4.4%, 5.5%および2.2%であり, いずれのEMAも10.0%以下だった. 各園地1樹のみでEMAを算出した場合, 果樹試A, BおよびC園のそれぞれ61.7%, 23.1%, 51.7%の樹でEMAが10.0%以下だった. 各園地5樹


を用いたEMAの算出の場合, 果樹試A園では92.0%, 果樹試B園では83.0%, 果樹試C園では96.0%のデータでEMAが10.0%以下だった. 各園地10樹を用いたEMAの算出の場合, 果樹試A園では100.0%, 果樹試B園では96.0%, 果樹試C園では100.0%と, ほぼ全てのデータでEMAが10.0%以下であった(図5-6).



(a) 果樹試A園での検証



(b) 果樹試B園での検証



(c) 果樹試C園での検証

図5-6 果実階級比率予測モデルに用いる樹数の違いがEMAに与える影響

### 5.3.4 生産者園における果実階級比率予測モデルの検証

香美EおよびG園のEMAは、それぞれ4.5%および7.5%と低かった。一方で、香美F,HおよびI園のEMAは、それぞれ11.3%、11.3%および12.5%とやや高かったが、全園においてピアソンの $\chi^2$ 検定で有意差が見られなかった(表5-6)。香美FおよびI園では、L級の実際の階級比率が60.0%以上であり、推定値と実測値の差も他園よりも大きかった(表5-7, 表5-8, 表5-9, 表5-10, 表5-11)。

表5-6 生産者園における果実階級比率予測モデルの検証

| 園地名 | EMA    | $p$ 値 <sup>z)</sup> |
|-----|--------|---------------------|
| 香美E | 4.5 %  | 0.977 n. s.         |
| 香美F | 11.3 % | 0.788 n. s.         |
| 香美G | 7.5 %  | 0.848 n. s.         |
| 香美H | 11.3 % | 0.330 n. s.         |
| 香美I | 12.5 % | 0.684 n. s.         |

z) ピアソンの $\chi^2$ 検定により, n. s. は有意差なし。

表 5-7 香美 E 園の果実階級別比率の予測値と実測値の差

| 果実階級             |       | S 級 | M 級 | L 級  | 2L 級 | 3L 級 | 総数 <sup>z)</sup> |
|------------------|-------|-----|-----|------|------|------|------------------|
| 予測値              | 玉数    | 25  | 60  | 709  | 1038 | 119  | 1951             |
|                  | 比率(%) | 1.3 | 3.1 | 36.4 | 53.2 | 6.1  | —                |
| 実測値              | 玉数    | 22  | 53  | 701  | 1081 | 92   | 1951             |
|                  | 比率(%) | 1.1 | 2.7 | 35.9 | 55.4 | 4.7  | —                |
| 誤差 <sup>y)</sup> | 玉数    | 3   | 7   | 8    | -43  | 27   | 0                |
|                  | 比率(%) | 0.1 | 0.3 | 0.4  | -2.2 | 1.4  | —                |

z) 玉数は規格外を除いた値のため、各階級の和と総数は一致しない。

y) 予測値から実測値を減じた値。

表 5-8 香美 F 園の果実階級別比率の予測値と実測値の差

| 果実階級             |       | S 級 | M 級  | L 級  | 2L 級 | 3L 級 | 総数 <sup>z)</sup> |
|------------------|-------|-----|------|------|------|------|------------------|
| 予測値              | 玉数    | 51  | 173  | 734  | 231  | 6    | 1195             |
|                  | 比率(%) | 4.3 | 14.5 | 61.4 | 19.3 | 0.5  | —                |
| 実測値              | 玉数    | 42  | 161  | 801  | 189  | 1    | 1195             |
|                  | 比率(%) | 3.5 | 13.5 | 67.0 | 15.8 | 0.1  | —                |
| 誤差 <sup>y)</sup> | 玉数    | 9   | 12   | -67  | 42   | 5    | 0                |
|                  | 比率(%) | 0.8 | 1.0  | -5.6 | 3.5  | 0.4  | —                |

z) 玉数は規格外を除いた値のため、各階級の和と総数は一致しない。

y) 予測値から実測値を減じた値。

表 5-9 香美 G 園の果実階級別比率の予測値と実測値の差

| 果実階級             |       | S 級  | M 級  | L 級  | 2L 級 | 3L 級 | 総数 <sup>z)</sup> |
|------------------|-------|------|------|------|------|------|------------------|
| 予測値              | 玉数    | 30   | 145  | 776  | 341  | 16   | 1308             |
|                  | 比率(%) | 2.3  | 11.1 | 59.3 | 26.1 | 1.2  | —                |
| 実測値              | 玉数    | 47   | 167  | 732  | 350  | 10   | 1308             |
|                  | 比率(%) | 3.6  | 12.8 | 56.0 | 26.8 | 0.8  | —                |
| 誤差 <sup>y)</sup> | 玉数    | -17  | -22  | 44   | -9   | 6    | 0                |
|                  | 比率(%) | -1.3 | -1.7 | 3.4  | -0.7 | 0.5  | —                |

z) 玉数は規格外を除いた値のため、各階級の和と総数は一致しない。

y) 予測値から実測値を減じた値。

表 5-10 香美 H 園の果実階級別比率の予測値と実測値の差

| 果実階級             |       | S 級  | M 級  | L 級  | 2L 級 | 3L 級 | 総数 <sup>z)</sup> |
|------------------|-------|------|------|------|------|------|------------------|
| 予測値              | 玉数    | 764  | 882  | 1266 | 121  | 0    | 3033             |
|                  | 比率(%) | 25.2 | 29.1 | 41.7 | 4.0  | 0.0  | —                |
| 実測値              | 玉数    | 657  | 995  | 1296 | 27   | 0    | 3033             |
|                  | 比率(%) | 21.7 | 32.8 | 42.7 | 0.9  | 0.0  | —                |
| 誤差 <sup>y)</sup> | 玉数    | 107  | -113 | -30  | 94   | 0    | 0                |
|                  | 比率(%) | 3.5  | -3.7 | -1.0 | 3.1  | 0.0  | —                |

z) 玉数は規格外を除いた値のため、各階級の和と総数は一致しない。

y) 予測値から実測値を減じた値。

表 5-11 香美 I 園の果実階級別比率の予測値と実測値の差

| 果実階級             |       | S 級 | M 級  | L 級  | 2L 級 | 3L 級 | 総数 <sup>z)</sup> |
|------------------|-------|-----|------|------|------|------|------------------|
| 予測値              | 玉数    | 45  | 141  | 648  | 314  | 15   | 1162             |
|                  | 比率(%) | 3.9 | 12.1 | 55.8 | 27.0 | 1.3  | —                |
| 実測値              | 玉数    | 31  | 136  | 721  | 270  | 4    | 1162             |
|                  | 比率(%) | 2.7 | 11.7 | 62.0 | 23.2 | 0.3  | —                |
| 誤差 <sup>y)</sup> | 玉数    | 14  | 5    | -73  | 44   | 11   | 0                |
|                  | 比率(%) | 1.2 | 0.4  | -6.3 | 3.7  | 0.9  | —                |

z) 玉数は規格外を除いた値のため、各階級の和と総数は一致しない。

y) 予測値から実測値を減じた値。

#### 5.4 考察

果実の大きさを推定する研究の多くは、果実個々の推定に焦点が当てられている (Hall et al. 1996, Marini et al. 2019b, Amaral and Walsh 2023) が、例えば、ワシントンネーブルオレンジでは、収穫まで 2 週間毎に測定した果実横径に基づき、Cubic Smoothing Spline Analysis を用いて果実直径を予測するモデルを開発し、さらに最終的な果実階級比率を検証した報告もある (Khurshid and Braysher 2009)。本章では、より省力的に園地全体の果実階級比率を予測するために、樹別の平均果実横径を利用することとした。まず、多項式回帰分析を用いて果実階級比率を予測するモデルを構築した。回帰モデルの信頼性を担保するためには、最小二乗法を用いた線形回帰の前提条件、すなわち、(a) 残差の独立性、(b) 残差の正規性、(c) 残差の等分散性および (d) 線形性を満たす必要がある (Kumari and Yadav 2018)。Ahad et al. (2011) および Ghasemi and Zahediasl (2012) は、正規性の検証に適した検定方法は Shapiro-Wilk 検定 (Shapiro and Wilk 1965) であると報告している。表 5-4 の結果では、2 つの式において有意差が見られなかったが、正規 Q-Q プロットはいずれの式においても特異な分布傾向を示さなかった (図 5-3)。よって、仮説 (b) を満たすと判

断した。また、全ての残差プロットで一貫した傾向が見られなかった (図 5-4) ことから、仮説 (a) および仮説 (c) を満たすと判断した。平均果実横径が 62.5 mm 以上の M 級を予測する五次多項式で AIC が最も低くなったが、四次多項式と五次多項式の AIC の差が、三次多項式と四次多項式の AIC の差より小さかったことから (表 5-4)、本章では  $R^2$  が高く、AIC が低い 4 つの四次多項式 (表 5-3) を、線形回帰の前提を満たす果実階級比率予測モデルとして以後の試験に用いた。

一般的に予測モデルは、複数年および複数の場所から得たデータセットを用いて構築することが望ましいとされる。本章の果実階級比率予測モデルは、1 つの果樹園の 1 年間で得られたデータセット (果樹試 A 園, 2020 年) に基づいて構築している。カンキツ類は他の果樹と比較して隔年結果性が強く (木原, 小中原 2000)、果実の大きさがばらつきやすいことを考慮すると、特に着果数の変動する複数のデータセットでモデル性能を確認する必要がある。そこで、さらに 3 つのデータセットを追加し、それらを組み合わせて構築した果実階級比率予測モデルの検証を行った結果、予測精度に明確な違いは見られなかった (表 5-5)。さらに、果実横径の経験累積分布関数は全ての園で標準正規分布に近似した (図 5-5)。Judd and

McAneney (1987)によると、水分ストレスはキウイフルーツの平均果実重量に影響を与えるが、果実重の分布形状には影響を与えないと報告している。ユズとは樹種および樹体に与えるストレスが異なるが、本章の結果が果実階級比率予測モデルのモデル構築園とは異なる着果数の園にも適用できることを示唆している。したがって、2020年の果樹試A園のデータセットにより構築した果実階級比率予測モデルは、着果数の異なる他の園地の予測にも用いることができると判断した。

果実階級比率の予測調査の省力化を図るためには、調査樹数毎の予測精度を把握する必要がある。予測に用いる樹数を違えてEMAを評価した結果、1園地当たり10樹の調査においてほぼ全てのデータでEMAが10.0%以下であった(図5-6)。ワシントンネーブルオレンジ(Khurshid and Braysher 2009)やリンゴ(Marini et al. 2019a)での研究でも、10樹以上の統合データで高い精度が達成されたことが報告されている。本章の結果のように、樹数を増やすことで果実階級比率の予測値が徐々に収束することは、園レベルで安定した推定を行うためには十分量のサンプリングが重要であることを示している。一方で、本章における樹の選択は単純無作為抽出法(Simple Random Sampling)に基づき実施した。園を代表する樹を選択する方法として、例えば、Multilevel Systematic Sampling(Wulfsohn et al. 2012)やRanked Set Sampling(Uribeetxebarria et al. 2019)、中庸サンプリング法(Random Median Sampling, Yamamura et al. 2007)等を適用することも考えられる。特にMultilevel Systematic Samplingは、果実数を迅速に正確に推定できる手法とされている。これらのサンプリング法も参考に、園全体の果実階級比率を推定するために必要なサンプリング方法を検討する必要がある。

生産者園における果実階級比率予測モデルの検証では、園毎に異なる傾向が見られた(表5-6)。香美F園およびI園の樹は他の園よりも葉が少なく、樹冠内部でも十分に光が当たっていた。Verreyne et al. (2004)は、3種類のカンキツ類(ウンシュウミカン、クレメンティンおよびフェアチャイルドタンゼロ)の果実のサイズは、上部および外側の果実が内部の果実よりも大きいと報告している。また、Suzuki et al. (1973)は、ウンシュウミカンの樹冠内部における光強度や気温等の微気象条件の変化と運動し、樹冠下部では中段や上段の果実よりも果実サイズが劣ることを指摘している。香美F園およびI園の結果(表5-8, 5-11)は、樹冠内外の光条件と気温が均一であったため、果樹の果実サイズがより均一となったことが原因であると考えられた。一方で、香美H園におけるS級およびM級の果実階級比率の推定値と実測値の差は、他の園よりも高かった(表5-10)。これらの園の果実は他の園の果実よりも小さく、規格外の果実も他の園よりも多かった。これは、湿害に

よる樹勢の低下が原因であると考えられた。しかし、香美F園、H園およびI園でも、EMAが約10%であり、香美E園およびG園は10%以下であった(表5-6)。したがって、本章で構築した果実階級比率予測モデルは、樹齢や着果数が異なる園地の予測にも適用できると考えられた。

以上より、多項式回帰を用いてユズの果実階級比率予測モデルを構築した。本手法を用いることで、収穫前に果実階級比率を高精度で予測できる。しかし実用化のためには、真の平均果実横径を把握するためのサンプリング手法の検討も必要である。

## 5.5 参考文献

- 1) Ahad, N. A., T. S. Yin, A. R. Othman and C. R. Yaacob (2011) Sensitivity of Normality Tests to Non-Normal Data (Kepekaan Ujian Kenormalan Terhadap Data Tidak Normal). *Sains Malaysiana*, 40(6):637-641.
- 2) Amaral, M. H. and K. B. Walsh (2023) In-Orchard Sizing of Mango Fruit: 2. Forward Estimation of Size at Harvest, *Horticulturae*, 9(1):54.
- 3) Ghasemi, A. and S. Zahediasl (2012) Normality Tests for Statistical Analysis: A Guide for Non-Statisticians, *International Journal of Endocrinology and Metabolism*, 10(2):486-489.
- 4) Hall, A. J., H. G. McPherson, R. A. Crawford and N. G. Seager (1996) Using Early-Season Measurements to Estimate Fruit Volume at Harvest in Kiwifruit, *New Zealand Journal of Crop and Horticultural Science*, 24(4):379-391.
- 5) Judd, M. J. and K. J. McAneney (1987) *Advances in Irrigation*, Academic Press: London, UK, 4, 307-330.
- 6) Khurshid, T. and B. Braysher (2009) Early Fruit Size Prediction Model Using Cubic Smoothing Splines for 'Washington Navel' (*Citrus sinensis* L. Osbeck) Oranges in Australia. *International Journal of Fruit Science*, 9(4):394-408.
- 7) 木原武士, 小中原実 (2000) ウンシュウミカンにおける隔年結果の現状と対策, *果樹試験場報告*, 34:111-136.
- 8) Kumari, K. and S. Yadav (2018) Linear Regression Analysis Study, *Journal of the Practice of Cardiovascular Sciences*, 4(1):33-36.
- 9) Marini, R. P., J. R. Schupp, T. A. Baugher and R. Crassweller (2019a) Sampling Apple Trees to Accurately Estimate Mean Fruit Weight and Fruit Size Distribution, *HortScience*, 54(6):1017-1022.

- 10) Marini, R. P., J. R. Schupp, T. A. Baugher and R. Crassweller (2019b) Estimating Apple Fruit Size Distribution from Early-Season Fruit Diameter Measurements, *HortScience*, 54(11): 1947-1954.
- 11) Shapiro, S. S. and M. B. Wilk (1965) An Analysis of Variance Test for Normality (Complete Samples), *Biometrika*, 52(3-4):591-611.
- 12) Suzuki, T., S. Okamoto, and T. Seki (1973) Effects of Micro-Meteorological Elements and Positions in the Tree Crown on the Development of Shoots, Leaves and Fruits of Satsuma Mandarin, *Journal of the Japanese Society for Horticultural Science*, 42(3):201-209.
- 13) Uribeetxebarria, A., J. A. Martinez-Casasnovas, B. Tisseyre, S. Guillaume A. Escolà, J. R. Rosell-Polo and J. Arnó (2019) Assessing Ranked Set Sampling and Ancillary Data to Improve Fruit Load Estimates in Peach Orchards, *Computers and Electronics in Agriculture*, 164, 104931.
- 14) Verreyne, J. S., E. Rabe and K. I. Theron (2004) Effect of Bearing Position on Fruit Quality of Mandarin Types, *South African Journal of Plant and Soil*, 21:1-7.
- 15) Wulfsohn, D., F. A. Zamora, C. P. Téllez, I. Z. Lagos and M. Garcia-Fiñana (2012) Multilevel Systematic Sampling to Estimate Total Fruit Number for Yield Forecasts, *Precision Agriculture*, 13:256-275.
- 16) Yamamura, K., T. Wada and S. Urano (2007) Random Median Sampling to Enhance the Precision of Population Estimates, *Population Ecology*, 49:357-363.

## 第6章 結 言

本研究では、果樹におけるスマート農業技術の実用化を促進するために、カンキツ類の出荷量予測に必要な生理生態情報の「見える化」を目的として、土佐文旦およびユズにおける着花量の定量化技術、LAI の測定技術、着果量の推定方法ならびに果実階級比率の予測技術を検討し、それぞれの精度を検証した。

第2章では、土佐文旦において花卉が白色であることに着目し、曇天日の空撮画像を用いて樹冠投影面積に占める白色面積を二値化し、推定花量として定量化する技術を開発した。RGB 画像をNTSC 加重平均法で8-bit グレースケール画像に変換して二値化する手法、またはBlue Channel 画像を二値化する手法を確立した。あわせて、PCAによるLAIの測定方法では、3天頂角を用い、直線回帰式により補正することで、実際のLAIが推定できることを示した。本手法を用いることで、開花期から収量を予測できると考えられる。また、生育期間中のLAIをモニタリングし、肥培管理を改善することで生産性の向上につながると考えられる。

第3章では、ユズにおいてLAIをせん定量の指標として用いるための技術を確立した。PCAによって主幹中心から距離80cmの4方位の位置より90°のビューキャップを装着して測定し、4天頂角で解析することで最も実際LAIに近いPCA-LAIの値が得られた。さらに、高知県内の生産者園の実態調査から高収量性かつ低隔年結果性を持つ園地を抽出し、それら園地のLAIがせん定量の目安となることが示唆された。本手法を用いてせん定量を一定にすることで、生産量および出荷量が安定し、出荷量予測も容易になると考えられる。

第4章では、ユズにおいて空撮画像から着果数の推定方法を確立するために、データ拡張により学習用データセットの画像数を違えて学習させた果実推定モデルの予測精度を比較するとともに、特定の園地および特定の天候の画像データセットにより学習させたモデルの予測精度を比較した。25枚の限ら

れた画像数のデータセットではYOLOv5muモデルが他のモデルよりも優れた性能を発揮した一方で、データ拡張によって学習用データセットの画像数を増やした場合、推定モデルの検出性能はYOLOv8mおよびYOLOv9cモデルがYOLOv5muモデルよりも向上した。また、学習用データセットに含まれる画像の撮影時の気象条件が不均衡であっても検出性能への影響は小さいが、学習用データセットに含まれない果実の着色程度は検出に与える影響が大きいことが明らかとなった。本手法を参考に、空撮方法やPix2pix等の高度なデータ拡張手法の検討、果実着色程度や枝葉等の遮蔽の影響を考慮したアノテーションを行って果実推定モデルを構築することにより、検出性能をより高められると考えられる。

第5章では、ユズにおける果実階級比率予測モデルを開発した。収穫時の平均果実横径と各階級比率データの多項式回帰分析により、2L級およびM級を予測するためのそれぞれ2つの四次多項式を適用した。さらに、予測モデルの精度を保証するためには、1園地当たり最低10樹を調査することが有効であった。さらに、高知県内の生産者園における予測モデルの検証の結果から、樹齢や着果数が異なる園地の予測にも適用できた。本手法を用いることで、収穫前に果実階級比率を高精度で予測できる。しかし実用化のためには、真の平均果実横径を把握するためのサンプリング手法の検討も必要である。

残された課題として、実用化に向けた測定機器のコスト削減やデータ取得条件に応じた精度向上等が必要である。例えばLAIの測定に用いるPCAは高価であり、生産現場で日常的に用いることは現実的ではない。そこで、スマートフォンで利用できるLAI推定アプリを、高知県農業技術センター果樹試験場とNECソリューションイノベータ株式会社が共同で開発している。また、果実推定モデルを用いた樹および園地全体の着果数を予測するモデルの開発や、さらに果実階級比率予測モデルを統合した総合的出荷量予測技術の開発も必要である。

## 摘要

日本のみならず世界の農業は、農業経営体数の大幅な減少が予測されており、サステナビリティ(持続可能性)の観点からも対応が急務である。このような情勢の中、農業の持続的な発展のためには、生産性の向上に資するスマート農業技術の更なる実用化が求められている。スマート農業技術を利用することで、作業の自動化、情報共有の簡易化およびデータの効率的な利用が可能となり、現在、様々な部門で研究開発および普及実装が進んでいる。しかし果樹栽培では、一部のスマート農業機器は利用されているものの急速な展開は見られない。これは、果樹は地域特性に応じて、多種多様な品目が栽培されており、データを効率的に活用するためには、品目毎の生理生態情報を「見える化」する技術の開発が必要となるためである。果樹での「見える化」が可能な生理生態情報のうち、出荷量予測に関する生理生態情報は、生育診断のみならず労務管理および販売戦略の策定においても極めて重要な情報である。特にカンキツ類は隔年結果性が強く、果実収量(=収入)が不安定となりやすい。また、事前に出荷数量と価格を決定しその契約に基づいて実施される相対取引では、収穫前の出荷量予測が必要であるが、生産現場で実施されている予測方法は精度が低いことが問題となっている。出荷量予測精度の向上は、農業経営体の収入が安定することにつながり、経営の安定化および規模拡大に至る好循環をもたらすと考えられる。

果樹における出荷量予測に関する生理生態情報として、着花量、着果量、果実サイズおよび葉面積指数(Leaf Area Index, 以下, LAI)が挙げられる。着花量は着果量を早期に予測するために重要な情報で、収穫前の着果量および果実のサイズは収量および出荷量に直接的に影響する情報である。また、LAIは果樹における生産性を向上させる上での指標となりうる。そのため、これら情報に関する簡易かつ精度の高い予測方法の開発が求められている。

したがって本研究では、高知県の特産カンキツ類である土佐文旦およびユズに焦点を当て、出荷量予測に関する生理生態情報、すなわち着花量の定量化技術、LAIの測定技術、着果量の推定方法ならびに果実階級比率の予測技術について、デジタル技術を用いて検討した。本博士論文は、6章から構成されており、緒論(第1章)と結論(第6章)を除く4つの章において、それぞれの結果を述べている。以下に、その要約を示す。

第2章では、土佐文旦における着花量の簡易測定技術およびLAIの測定技術を検討した。まず、土佐文旦の花弁が白色であることに着目し、曇天日の空撮画像を用いて樹冠投影面積に占める二値化の白色の面積を花量と仮定し、推定花量として定量化した。二値化の方法を検討した結果、RGB画像をNTSC加

重平均法で8-bit グレースケール画像に変換し、閾値の最小値0および最大値195で二値化する手法、またはBlue Channel画像を最小値0および最大値155で二値化する手法が採用できると考えられた。次に、プラントキャノピーアナライザー(Plant Canopy Analyzer, 以下, PCA)によるLAIの測定方法を検討した結果、測定には3天頂角を用い直線回帰式により補正することで、実際のLAIが推定可能であった。最後に、これらの測定技術を用いて花量、収量およびLAIの関係を調査した。同年の推定花量と収量にはやや強い正の相関が、前年収量と当年推定花量の関係にはやや強い負の相関が見られ、測定技術の有用性が確認された。

第3章では、ユズにおけるせん定の定量化の指標としてLAIに着目し、PCAの測定技術を検討した。検討の結果、測定には4天頂角を用いることで、最も実際LAIに近いPCA-LAIの値が得られた。さらに、生産者園の実態調査から、樹冠容積当たりの収量が $2.1 \text{ kg/m}^3$ 以上の収量(高収量性)かつ隔年結果指数が0.30未満の安定した収量(低隔年結果性)が得られている園地を抽出した。解析の結果より、ユズにおける適正なせん定量の目安は、一般的な栽植密度である植栽間隔が概ね $4.0 \times 3.0 \text{ m}$ の場合、樹冠面積率は80%以下とし、せん定後LAIは3.7、LAI減少量は1.7、LAI減少率は30.6%とするのが妥当と考えられた。

第4章では、ユズにおいて空撮画像からの着果数の推定方法を確立するために、データ拡張により学習用データセットの画像数を違えて学習させた果実推定モデルの予測精度を比較するとともに、特定の園地および特定の天候の画像データセットにより学習させたモデルの予測精度を比較した。25枚の限られた画像数のデータセットではYOLO(You Only Look Once)v5muモデルが他のモデルよりも優れた性能を発揮した一方で、データ拡張によって学習用データセットの画像数を増やした場合、推定モデルの検出性能はYOLOv8mおよびYOLOv9cモデルがYOLOv5muモデルよりも向上した。また、学習用データセットに含まれる画像の撮影時の気象条件が不均衡であっても検出性能への影響は小さいが、学習用データセットに含まれない果実の着色程度は検出に与える影響が大きいことが明らかとなった。

第5章では、多項式回帰を用いたユズの果実階級比率予測モデルを構築した。収穫直後に測定した平均果実直径と各階級比率データの多項式回帰分析により、2L級およびM級を予測するためのそれぞれ2つの四次多項式モデルを構築した。さらに、着果数の異なる3つの園地から得られた4つのデータセットを組み合わせて構築したモデルと比較した。モデルの精度

は,EMA (Estimation Model's Accuracy, 各果実階級比率の実際値と推定値の差の絶対値の総和)により評価した. その結果, 14の異なるデータセットを用いて構築した果実階級比率予測モデルにより 28回の検証を行った結果, EMAは2.0~6.1%と10.0%以下であった. さらに, 予測に用いる樹数を違えてEMAを評価した結果, 1園地当たり10樹の調査においてほ

ぼ全てのデータでEMAが10.0%以下であった. 最後に, 生産者園における果実階級比率予測モデルの検証では, 2園地のEMAは10.0%以内, 3園地のEMAは11.3~12.5%の範囲内であった. これらの結果から, 構築したモデルは着果数が異なる園地にも適用でき, 1園地当たり最低10樹を調査することにより, 高精度で果実階級比率が予測できることを明らかにした.

## Summary

Agriculture worldwide, including in Japan, faces significant challenges due to a sharp decline in the number of agricultural management entities. Addressing these issues from a sustainability perspective is urgent necessity. Sustainable agricultural development requires the implementation of smart farming technologies that enhance productivity. These technologies enable automation, simplified information sharing, and efficient data utilization. Consequently, research and development of such technologies are advancing across various agricultural sectors. However, the rapid adoption of smart farming technologies in fruit cultivation has not yet been achieved. This is primarily due to the diverse range of fruit crops cultivated, reflecting regional characteristics, which necessitates the development of technologies to “visualize” crop-specific physio-ecological information for effective data utilization. Among the various types of physio-ecological information critical for fruit cultivation, yield prediction data is vital, not only for assessing growth but also for labor management and sales strategy planning. Notably, strong biennial bearing tendencies in citrus species often result in fluctuating yields, leading to income instability. Additionally, in negotiated transactions, where shipping quantities and prices are predetermined by contract, accurate preharvest yield predictions are essential. However, existing yield prediction methods often lack precision. Improving yield prediction accuracy is expected to stabilize the income of agricultural entities, promoting operational stability and scaling-up, thus fostering a virtuous cycle.

The physio-ecological information relevant to yield prediction in fruit cultivation includes flowering quantity, number of fruit sets, fruit size, and leaf area index (LAI). The quantity of flowers is an important piece of information for predicting the number of fruit sets. The preharvest number of fruit sets and fruit size directly influenced yield and shipping quantities. Furthermore, LAI serves as an indicator of productivity improvement in fruit cultivation. Hence, it is crucial to develop simple and accurate prediction methods for this type of information.

My study focuses on the development of digital technologies to quantify flowering, measure LAI, estimate the number of fruit sets, and predict the proportion of fruit size grade for ‘Tosa-Buntan’ pummelo (*Citrus maxima* (Burm.) Merr.), and yuzu (*Citrus junos* Sieb. ex Tanaka.), a specialty citrus fruit from Kochi Prefecture, Japan. This dissertation comprises six chapters, including an introduction (Chapter 1) and a conclusion (Chapter 6), with the results presented in four chapters. The conclusions are as follows:

### <Chapter 2>

In this chapter, simple measurement methods for quantifying flowers and LAI in ‘Tosa-Buntan’ were explored. Considering the white coloration of ‘Tosa-Buntan’ petals, white areas within binarized images from overcast aerial photography were quantified to estimate the quantity of flowers. As a result, binarization was most accurate when either RGB images were converted to 8-bit grayscale by the NTSC weighted-average method and binarized using minimum and maximum threshold values of 0 and 195 or the Blue Channel images were binarized using minimum and maximum threshold values of 0 and 155. LAI measurements using a plant canopy analyzer (PCA) were adopted by employing three zenith angles for correction via linear regression to estimate the actual LAI. The estimated quantity of flowers in the current year had a strong positive correlation with yield in the current year and a strong negative correlation with yield in the previous year, confirming the suitability of the measurement techniques.

### <Chapter 3>

PCA measurement methods were evaluated by focusing on LAI as a pruning quantification index for yuzu.

As a result, the PCA-LAI values closest to the actual LAI were obtained using four zenith angles for the PCA measurement. Surveys in farmer's orchards identified orchards with high productivity ( $\geq 2.1 \text{ kg/m}^3$  yield) and low biennial bearing index ( $< 0.30$ ). Based on the analysis results, it was deemed reasonable to set the appropriate pruning amount for yuzu at a typical planting density of approximately  $4.0 \times 3.0 \text{ m}$ , with a crown area ratio of 80 % or less, LAI after pruning of 3.7, LAI reduction of 1.7, and LAI reduction rate of 30.6 %.

#### <Chapter 4>

The accuracy of fruit detection models trained with datasets of varying sizes was compared to develop a method for estimating the number of fruit sets in yuzu via aerial imagery. Using a constrained dataset (25 images), the YOLOv5mu model outperformed the YOLOv8m and YOLOv9c. However, with data augmentation, and an increased number of training images, the YOLOv8m and YOLOv9c models surpassed YOLOv5mu in detection performance. Although weather condition information in the training dataset had a minimal impact on detection performance, the absence of fruit coloration information significantly affected detection performance.

#### <Chapter 5>

Polynomial regression models were developed to estimate the proportion of fruit size grades in yuzu. Curvilinear regression analysis of mean fruit diameters measured postharvest and the proportion of each fruit size grade led to the construction of two quartic function equation models for predicting the 2L and M size grades. A comparative analysis using datasets from three orchards with varying numbers of fruit sets revealed the accuracy of the EMA models (defined as the sum of the absolute differences between the actual and estimated proportions of each grade). Among 28 validations, EMA values ranged from 2.0 % to 6.1 %, below the 10.0 % threshold. Surveys involving at least 10 trees per orchard achieved EMA values under 10.0 % in most cases. Validations in farmer's orchards yielded EMA values within 10.0 % for two orchards and 11.3–12.5 % for three, demonstrating the models' applicability to orchards with varying number of fruit sets. Moreover, acceptable accuracy was achieved by investigating at least 10 trees simultaneously.

## 謝 辞

本研究は、令和4年度、5年度および6年度高知県大学院(博士課程後期)派遣研修事業により、高知県農業技術センター果樹試験場に在籍し、実施したものです。また、第3章および第5章は、内閣府地方大学・地域産業創生交付金「IoP(Internet of Plants)」が導く「Next 次世代型施設園芸農業」への進化の助成を受け、第4章は、内閣府地方大学・地域産業創生交付金「IoP(Internet of Plants)」が導く「Society5.0型農業」への進化の助成を受けて実施しました。

研究の遂行にあたっては、果樹試験場 元場長 中野和彦氏には、本研究を始めるきっかけを与えていただくとともに、進学の後押しをしていただきました。前場長 二宮千登志氏には、研究計画の立案や論文の執筆に際し、ご自身の経験から様々なご助言、ご協力をいただきました。さらに、果樹試験場の職員および元職員の皆様には、日々の管理作業および調査の補助等で多大なご配慮、ご協力をいただきました。高知県農業振興部の職員の皆様には、事務および現地調査等で多大なご支援をいただきました。ここに記して深く感謝申し上げます。

現地調査にあたっては、高知県香美市および安芸市の生産者および関係者の皆様には、多くのご協力をいただきました。特に、私が高知県中央東農業振興センター在籍時に普及指導活動を通じて交流した、高知県農業協同組合物部柚子生産部会の生産者の皆様ならびに高知県農業協同組合香美地区香美営農経済センター物部購買課・集出荷場の職員の皆様には、本研究開始後も現地調査にご協力いただくとともに、常日頃から生産現場における現状、課題について議論する機会をいただきました。厚くお礼申し上げます。

研究の遂行と取りまとめにあたっては、高知工科大学大学院工学研究科 教授 吉田真一博士には多大なご配慮とご指導をいただきました。専門研究分野の異なる私の進学を快く受け入れてくださり、終始温かいご指導、激励をいただきました。心から感謝いたします。

令和8年3月

谷本 佑

令和8年3月1日 発行

編集発行者

高知県農業技術センター

〒783-0023 高知県南国市廿枝 1100 番地

TEL 088-863-4912



高知県農業技術センター

高知県南国市甘枝1100

KOCHI AGRICULTURAL RESEARCH CENTER

Hataeda 1100, Nankoku Kochi 783-0023, Japan