

博士論文

画像解析と機械学習によるトマトの自動生育診断 および高速フェノタイピングに関する研究

東京大学 大学院 農学生命科学研究科

農学国際専攻

平成 24 年度 博士課程入学

山本 恭輔

目次

第 1 章	緒言	1
1.1	研究背景	1
1.2	研究目的	5
1.3	本論文の構成	8
第 2 章	生育初期におけるトマト樹体画像からの節検出および節間距離推定	10
2.1	はじめに	10
2.2	節検出および節間距離推定手法	12
2.2.1	一般物体認識	12
2.2.2	k -means 法	15
2.2.3	Affinity Propagation	16
2.2.4	節検出手法	18
2.2.5	節位推定手法	23
2.2.6	節間距離推定手法	24
2.3	解析試料および方法	24
2.3.1	画像取得	24
2.3.2	機械学習手法のパラメータ決定	26
2.3.3	性能評価	27
2.4	解析結果	28
2.4.1	節検出	28
2.4.2	検出節の節位推定	28
2.4.3	節間距離推定	30
2.5	考察	31

第 3 章	着果期以降におけるトマト樹体画像からの自動果実検出	38
3.1	はじめに	38
3.2	果実検出手法	40
3.2.1	Pixel-based segmentation	40
3.2.2	Blob-based segmentation	40
3.2.3	個別果実検出	42
3.3	解析試料および方法	43
3.3.1	画像取得	43
3.3.2	機械学習手法のパラメータ決定	52
3.3.3	性能評価	52
3.4	解析結果	54
3.4.1	Blob-based segmentation による誤判別除去	54
3.4.2	時系列トマト樹体画像からの果実検出	56
3.4.3	栽培ベッド内における着果数分布の推定	57
3.5	考察	59
第 4 章	画像解析を用いた果実外観特徴の定量的評価	65
4.1	はじめに	65
4.2	解析試料および方法	67
4.2.1	解析試料	67
4.2.2	画像取得	67
4.2.3	外観特徴解析手法	71
4.2.4	外観特徴データに基づく外観特徴距離の定量評価	73
4.3	解析結果	74
4.3.1	外観特徴の定量評価	74
4.3.2	外観特徴距離の定量評価	78
4.4	考察	79
第 5 章	総合考察	95
5.1	本研究の成果	95
5.2	今後の課題	97

目次	iii
付録 A 表色系	100
A.1 RGB 表色系	100
A.2 HSV 表色系	102
A.3 $L^*a^*b^*$ 表色系	102
A.4 $L^*u^*v^*$ 表色系	103
A.5 YCbCr 表色系	104
付録 B 非階層的クラスタリング手法の比較	106
摘要	114
謝辞	117
参考文献	119

目次

2.1	一般物体認識で用いられる画像例	12
2.2	学習過程における Bag of Features の概略図	14
2.3	検証過程における Bag of Features の概略図	15
2.4	Affinity Propagation における責任度の概略図	18
2.5	節検出手法のフローチャート	19
2.6	GUI アプリケーションによる学習データ抽出	20
2.7	茎画像の生成例	21
2.8	節候補点の抽出例	22
2.9	主茎検出および節候補点削除の例	23
2.10	節間距離の誤推定例	24
2.11	節位推定手法のながれ	25
2.12	実際の節直線と推定された節直線の関係	29
2.13	実節間距離と推定節間距離の関係	32
2.14	節検出結果の一例	34
2.15	つくば植物工場内を走行可能な自走式ロボット	37
2.16	Mobile Robot Field Server	37
3.1	果実検出手法のフローチャート	41
3.2	Blob-based segmentation で用いた学習データの例	42
3.3	複数の果実を含む領域からの個別果実検出	45
3.4	x -means 法の概略図	46
3.5	農業・食品産業技術総合研究機構の植物工場 つくば実証拠点の施設の概略図	47
3.6	トマト栽培施設内の様子	48

3.7	トマト栽培施設内の概略図および樹体画像の撮影位置	49
3.8	時系列のトマト樹体画像	50
3.9	トマト栽培ベッドのパノラマ画像	51
3.10	本研究における果実熟度の定義	53
3.11	Blob-based segmentation による誤判別削除の例	54
3.12	Blob-based segmentation における各特徴量の重要度	55
3.13	画像分割の例	56
3.14	栽培ベッド内での着果数分布	58
3.15	難しい条件下における果実検出の例	62
3.16	異なる条件下における最適な窓サイズの例	62
4.1	各品種の外観特徴	68
4.2	色彩画像撮像装置の外観	70
4.3	色彩画像撮像装置の概略図	70
4.4	$L^*a^*b^*$ 表色系	71
4.5	それぞれの色彩主成分が表す色彩変化	75
4.6	色彩主成分スコアの品種内でのばらつき	77
4.7	各形状主成分が表す形状変化	83
4.7	各形状主成分が表す形状変化 (cont)	84
4.8	農林水産省によって定められたトマト果実の形状カテゴリ	85
4.9	各品種の平均果実形状	86
4.10	形状主成分スコアの品種内でのばらつき	87
4.10	形状主成分スコアの品種内でのばらつき (cont)	88
4.11	果実重量と果実サイズの関係	89
4.12	果実サイズの品種内でのばらつき	89
4.13	色彩主成分スコアから得られた果実間距離に多次元尺度構成法を適用した結果	90
4.14	赤系と桃系のトマトがプロットされた領域を拡大	91
4.15	形状主成分スコアから得られた果実間距離に多次元尺度構成法を適用した結果	92
4.16	果実サイズの変化の視覚化	93
4.17	品種判別における各特徴量の重要度	94

A.1	CIE RGB 等色関数	101
A.2	CIE XYZ 等色関数	101
B.1	マウスデータセットに対して各手法を適用した結果	110
B.2	各クラスタリング手法を用いた検出節の節位推定	111
B.3	各クラスタリング手法を用いた複数果実領域からの個別果実検出	112
B.4	Affinity Propagation による複数果実領域からの個別果実検出	113

表目次

1.1	トマトの品種登録時における計測項目	6
2.1	解析に用いたトマト株の品種、播種日、撮影期間および撮影画像数	26
2.2	各トマト株から抽出した学習データ数	27
2.3	節検出の性能評価結果	30
2.4	節間距離推定の性能評価結果	31
3.1	時系列トマト樹体画像からの果実検出結果	57
3.2	栽培ベッドパノラマ画像からの果実検出結果	57
3.3	1 区画あたりの検出果実数と実際の果実数の間の相関関係	59
4.1	解析に用いた試料の品種一覧	69
4.2	色彩画像撮像装置の部品一覧	69
4.3	果実表面における色彩特徴の主成分分析結果	74
4.4	楕円フーリエ記述子の主成分分析結果	76
4.5	各品種の平均形状主成分スコア	78
4.6	全特徴量を用いた品種判別における各品種の判別結果	80
B.1	非階層的クラスタリング手法の比較	107
B.2	各クラスタリング手法の計算時間	109

第 1 章

緒言

1.1 研究背景

近年の日本の農業は、農業従事者の高齢化が進む一方で、後継者が不足するという深刻な問題に直面している。実際の農業就業人口の推移を見てみると、昭和 60 年の 636 万人から平成 24 年の 251 万人と約 30 年間に 60% も減少しており、しかも 60 歳以上の高齢者が占める割合は 75% にも達している [222, p.87]。日本は世界有数の農業技術を有する国であるが、これは農業機械の発展のみならず、優れた技術を持つ篤農家の存在が非常に大きい。しかし担い手不足の問題が進む現在では、これらの技術の伝承が難しい状況にあり、日本の農業技術の低下が懸念されている。我が国の高度な農業技術を支えた農業者の約 7 割がこれから数年の間に離農するとも言われており [221]、こうした中で、今日では、収量の安定確保や高品質農産物の安定生産を達成するための技術の構築が急務となっている。

このような課題の解決策の 1 つとして、精密農業があげられる。米国の National Research Council のレポート [119] によれば、精密農業は「情報技術を駆使して作物生産に関わる多数の要因から空間的にも時間的にも高精度のデータを取得・解析し、複雑な要因間の関係性を科学的に解明しながら意思決定を支援する営農戦略体系である」と定義されている（濫澤 [220] の和訳を引用）。すなわち精密農業とは、従来の経験や勘に基づいて行われてきた農業を、データと科学的根拠に基づく農業へと発展させるための戦略であると言える。

精密農業は、「圃場マッピング技術」、「意思決定支援システム」、「可変作業技術」という 3 つの要素技術によって構成される [220, p.7]。圃場マッピング技術とは、圃場における気象や土壌などの環境、作物の生育状態、雑草や病害虫の発生頻度の空間的・時間的ばらつきを把握するための技術を指し、主にセンサーネットワークやリモートセンシングなどの技術が利用される。また、意思決定支援システムは農作業などの行動を決断するための支援技術であり、農産物の品質向上や生産性の向上、

収益の最大化、環境負荷軽減など農家が設定した目標を達成するための意思決定支援が行われる。最後に、可変作業技術は圃場や作物の状態などに従って農薬や肥料などの投入量を柔軟に変化し、最適化するための技術を指し、これによって環境負荷の低減や資材コストの最適化などが期待できる。この中で、精密農業の実現において基盤となるのが圃場マッピング技術、特に圃場における作物の生育状態の空間的・時間的ばらつきを把握することである。意思決定支援システムと可変作業は実際の作物の生育状態のばらつきに基づいて実行されることから、圃場マッピング技術が確立されて初めて他の2つが実現されると言っても過言ではない。

食品の安全確保や環境保全の観点からも、精密農業の重要性は高い。堆肥や化学肥料、あるいは農薬が環境リスクを考慮せずに過剰に使用された場合には、土壌や水、大気を汚染する危害要因となる [213, p.107]。一方で、精密農業では、圃場における作物の生育状態のばらつきに基づいて農薬等の使用量が最適化されるため、環境負荷が低減されるとともに、生産性の向上までもが期待できる [11, 154]。また、最近では、食品の安全確保や環境保全の観点から農林水産省が適正農業規範 (Good Agricultural Practice、以下、GAP という) の実施を推奨しているが、各生産工程の管理を適正化して記録する精密農業では、GAP に基づく農業の推進への貢献も期待できる [231]。

以上のことから、栽培の観点から見た、作物の生育状態を正確に把握することの重要性の高さが伺える。一方、近年では、栽培面ばかりでなく、育種分野においても同様の技術が必要とされ始めている。

この数年の高速シーケンサの発達によるゲノム解析の革新的な高速化は、大量の遺伝情報を生成し、イネ [66, 189] やトマト [166]、イチゴ [63] など様々な作物のゲノム配列情報が解明されてきた。膨大な遺伝情報を活かすためには、その遺伝情報がどのように表現型として発現するかを知る必要がある [228]。しかし表現型の計測は、多くの場合、破壊的で人力に依存する方法によって行われており、研究開発のボトルネックになっている。また、遺伝子型が一つの生物個体に対して原則として一意に決定できるのに対し、表現型は環境との相互作用によって多様に変化する。そのため、遺伝子型と表現型の関係を明らかにするためには、多様な環境での観測が必要となり、その結果として計測すべき表現型の量も爆発的に増えてしまう [228]。従って、育種開発をより効率化するためには、作物のゲノム解析と表現型解析を平行して加速化することや、環境との相互作用によって変化する作物の生育状態を的確に把握することが必要となる。

表現型解析における種々の問題を解決する学問分野として、フェノミクス (Phenomics) がある。先述の問題を背景に、近年ではフェノミクスに関する研究が活発化してきた [40, 46, 64, 81]。特に表現型解析の高速化を目的として開発された技術を高速フェノタイピング (High-throughput

phenotyping) と呼び、葉 [18, 51, 167, 172] や根 [25, 43, 71, 140, 195]、穂 [36]、果実 [32]、穀物 [163]、あるいは植物全体 [49, 50, 58, 80, 94, 138, 146, 194] を総合的に解析するための高速フェノタイピングツールやプラットフォームが開発されてきた。また、Jülich Plant Phenotyping Centre^{*1}や The Plant Accelerator^{*2}、High Resolution Plant Phenomics Centre^{*3}、Australian Centre for Plant Functional Genomics、IPK Gatersleben^{*4}、Institut National de la Recherche Agronomique^{*5}などの施設では実際にこれらの技術を導入しており、植物の生長を包括的に解析し理解するための研究が行われている。

表現型は大きく、形態や行動といったような「視覚判断できる表現型」と、含有物質やあるいは人間で言えば血液型といったような「視覚判断できない表現型」の2つに分けることができる。この中で、近年、高速フェノタイピングの対象とされることが多いのが「視覚判断できる表現型」であり、例えば植物で言えば、果実の色彩や形状、葉の模様、根の形態、草姿や樹体の成長速度といったような、植物の生育状態を把握するうえでも重要な役割を果たしている特徴を指す。これらの表現型は従来、人間の目視観察によって評価されてきた。そして、この評価を自動化する術として頻繁に用いられているのが、画像解析である。画像解析を用いるメリットとして、まず、非破壊非接触での計測が可能であるということがあげられる。また、評価者の経験や勘に依存しない客観的かつ定量的な評価が可能であるということも、画像解析を用いることで得られる大きな利点である。さらに、これまでの目視観察による評価方法では、作業コストが大きいために計測頻度に限界があったが、画像解析によって計測が自動化されることによって、時系列上の表現型の変化というこれまでには計測の難しかった特徴を抽出することも可能になる。先にも述べたように、視覚判断できる表現型の多くは植物の生育状態に関連する特徴でもあることから、それらの特徴の自動評価が可能になるということは、育種と栽培の両方において大きな意義を持つと言える。

先述のように、これまでに多くの高速フェノタイピングに関する技術が開発されてきた。しかしながら、それらの多くは特別な実験環境や独自の施設での利用を条件としており、実際の育種圃場での利用は想定されていなかった。一方で、植物の表現型は、その植物の遺伝子型と栽培環境、さらには両者の相互作用によって形成されるものであり、そのような特別な環境で栽培された植物の表現型は、実際の育種圃場で栽培されたものと異なることが多い [5, 130]。また、多くの作物が屋外で栽培されていることから、作物の自動生育診断という観点からも高速フェノタイピングは実圃場で行われ

^{*1} <http://www.fz-juelich.de>

^{*2} <http://www.plantphenomics.org.au/services/accelerator>

^{*3} <http://www.plantphenomics.org.au/services/hrppc>

^{*4} <http://www.ipk-gatersleben.de>

^{*5} <http://www.inra.fr>

ることが望ましい。こうした中で、近年では、実圃場でも利用可能な高速フェノタイピング技術に関する研究が行われ始めている [3–5, 28, 29, 52, 73, 97, 107, 113, 115, 116, 130, 137, 144, 169, 176]。その多くは可視画像解析を用いているものの、実圃場では照明条件などの撮影環境の不均一性が問題となることから、画像から対象作物の表現型に関する情報を抽出することは容易ではない。加えて、植物は生育段階や生育状態によって様相が大きく変化することも、画像解析による表現型解析の大きな障害となる。そのため、実圃場における高速フェノタイピング技術の開発は表現型計測および生育診断の自動化における大きな課題の1つとして未だ残されている。

作物の表現型の評価は、栽培期間だけでなく収穫後においても重要となる。従来、収穫した農作物の表現型の評価は農家や育種家などの目視観察によって行われてきた。しかし、農産物を製品としてとらえた場合、農産物の加工業者や消費者が希望する品質の設計、その数値化を含めた定量的評価の確立などが課題となる。また、遺伝情報との総合的な解析を考えると、農作物の表現型は定量化されていることが望ましい。そこで、従来の目視評価に変わる評価法として、特に色彩については色彩色差計や分光測色計といった光学機器を用いた農産物の管理や評価の試みがなされているが、そもそも人の目による管理や評価は部分的な評価の足し合わせではなく、全体の印象も含めて行われることが多い。そのため、分光測色計などを用いた部分的な評価ではなく、2次元情報としての色彩計測や形状計測などが可能な評価法の確立が望まれてきた。こうした課題の解決策として画像解析が長らく用いられており、トマト [16, 91, 102, 153, 164, 216, 234] やイチゴ [98, 158, 185–188, 215, 224–226, 237]、リンゴ [23, 93, 181, 182, 206]、オレンジ [82, 104, 105]、ブドウ [84, 85]、レモン [78, 102]、ライチ [20]、メロン [198]、コメ [99, 177, 197]、オオムギ [120]、ヘーゼルナッツ [129] などで外観特徴の評価技術が開発されてきた。

以上のことから、近年では、栽培と育種の両面において、作物の生育状態を的確に把握するための技術開発の重要性が高まっていることがわかる。また、既往研究の結果から、この目的に対する画像解析の有用性が高いことは明らかである。一方で、作物の外観特徴の計測には豊富な経験と知識を要するように、対象作物が違えば計測すべき項目や評価方法も異なる。また、同種の作物であっても評価されるべき項目は多岐に渡り、例えばナスでは 50 種類、キュウリでは 64 種類、トマトでは 71 種類もの表現型に関する特徴を品種登録のために計測する必要がある [230]。表現型の自動定量計測に関する技術は既に多く提案されてはいるものの、計測対象とされている表現型はそのごく一部であることから、生育状態を的確に把握するための技術開発は未だ発展途上であると言える。

ここで、品種登録時の計測項目数が比較的多いトマトにおける計測項目の一覧を表 1.1 に示す。同表では、画像解析によって計測可能であると考えられる項目を下線で示しているが、該当する項目が

多いことから作物の表現型解析に対する画像解析の有用性の高さが伺える。また、同表に示した計測項目は、花、果実、葉、莖といった器官ごとに関連する項目と、耐虫耐病性、遺伝子に関連する項目に大別することができる。その中で、トマトの生育診断の指標としても用いられる形質を記号 (†) で示した。これらの形質は育種開発の場面においても同様に計測されるが、その計測は個体ごとに農家や育種家などの目視観察によって行われる。そのため、計測にかかる作業コストが極めて大きいことが育種開発、栽培管理などにおいて問題とされてきた。したがって、これらの形質計測を自動化、高速化することは、育種と栽培の両方において大きな意義を持つ。一方で、従来、これらの形質の計測は実圃場で行われてきたことから、画像解析によって計測を自動化する場合にも同様に、実圃場での計測に対応することが望ましい。しかしその場合、先に述べたように撮影条件や作物の状態の不均一性が画像解析を適用するうえでの大きな課題となる。また、表 1.1 において記号 (‡) で示した形質は、定量的かつ連続的な変化を示すにも関わらず、専門家の目視観察によって定性的に評価される形質である。このように人力に頼った評価方法では作業コストが大きいことに加え、評価者が作業経験の積み重ねによって獲得した判断要因や判断基準に頼ることが多く、客観性に欠けることが問題視されてきた。また、定性的な評価を行うことで、外観特徴の微細な差異に関する情報が失われてしまうという問題も生じている。このような理由から、従来の評価指標を代替する、定量的かつ客観的な外観特徴の評価手法や評価指標の開発が強く望まれている。

1.2 研究目的

本研究の目的は、作物画像から生育状態に関わる情報を抽出するための画像解析技術を開発し、精密農業の実現のための要素技術や高速フェノタイプング技術としての実用化の可能性を見出すことにある。また、開発する技術は、実際に育種開発や栽培が行われる環境に近い条件であっても利用できるものにする 것도 目的の 1 つである。さらに本研究では、栽培期間と収穫後を含めた複数の栽培ステージにおいて作物の生育状態を定量的に評価するための画像解析技術の確立を目指す。

対象作物には、日本における需要が高く、特に品質が重要視されているため精密な管理が求められるトマトをモデル作物として用いる。本研究では、トマトの栽培ステージを生育初期、着果期以降、収穫後の 3 つに分け、それぞれで生育状態を的確に把握するための画像解析技術を開発する。各生育ステージにおいて計測対象とする形質を、表 1.1 に示した計測項目や、育種開発、作物の生育診断において特に重要とされる形質の中から選抜し、それらの評価を自動化するための技術を開発する。

まず生育初期においては、表 1.1 に示した計測項目のうち、莖に関連する表現型の 1 つである節間距離を自動計測するための画像解析技術を開発する。節間距離には、栽培環境のストレスによる影響

表 1.1 トマトの品種登録時における計測項目 [230]。画像解析によって計測可能と思われる項目に下線を引いた。

関連する部 位/項目	計測項目
花	<u>花の帯化</u> 、 <u>花卉の色</u> [‡] 、 <u>開花の早晚</u> [†] 、 <u>単為結果性</u> 、 <u>稔性区分</u>
果実	<u>果柄の離層</u> 、 <u>果柄の長さ</u> 、 <u>果実の大きさ</u> [†] 、 <u>果径比</u> [†] 、 <u>縦断面の果形</u> ^{†‡} 、 <u>果肩部のひだ</u> ^{†‡} 、 <u>横断面の果形</u> ^{†‡} 、 <u>こうあ部のくぼみ</u> [‡] 、 <u>へた落ちの大きさ</u> 、 <u>花落ちの大きさ</u> [‡] 、 <u>果頂部の形</u> ^{†‡} 、 <u>果実表皮の色</u> ^{†‡} 、 <u>果実の心の大きさ</u> [‡] 、 <u>果肉の厚さ</u> 、 <u>子室数</u> 、 <u>幼果期の果肩部の緑色の有無</u> [†] 、 <u>幼果期の果肩部の緑色の大きさ</u> ^{†‡} 、 <u>幼果期の果肩部の緑色の強さ</u> ^{†‡} 、 <u>幼果期の果色</u> ^{†‡} 、 <u>完熟期の果色</u> ^{†‡} 、 <u>完熟期の果肉色</u> [‡] 、 <u>果実の硬さ</u> [†] 、 <u>棚持ちの良さ</u> 、 <u>成熟の早晚</u> [†] 、 <u>果実表皮の種類</u> [‡] 、 <u>糖度（可溶性固形物含量）</u> 、 <u>酸度</u> 、 <u>全固形物量</u> 、 <u>スクロース含量の有無</u> 、 <u>リコピン含量</u>
葉	<u>葉の着生角度</u> ^{†‡} 、 <u>葉長</u> [†] 、 <u>葉幅</u> [†] 、 <u>葉の欠刻</u> ^{†‡} 、 <u>小葉の大きさ</u> ^{†‡} 、 <u>葉の緑色の強さ</u> ^{†‡} 、 <u>小葉の着生角度</u> ^{†‡} 、 <u>葉の上面の膨らみ</u> [‡] 、 <u>草姿</u> ^{†‡}
茎	<u>胚軸のアントシアニンの着色の有無</u> 、 <u>茎のアントシアニンの着色</u> 、 <u>節間距離</u> [†] 、 <u>心止まり性の強弱</u>
耐虫耐病性	<u>サツマイモネコブセンチュウ抵抗性</u> 、 <u>半身萎凋病抵抗性</u> 、 <u>萎凋病レース 1 抵抗性</u> 、 <u>萎凋病レース 2 抵抗性</u> 、 <u>萎凋病レース 3 抵抗性</u> 、 <u>根腐萎凋病抵抗性</u> 、 <u>葉かび病レース 0 抵抗性</u> 、 <u>タバコモザイクウイルス Tm-1 型抵抗性</u> 、 <u>タバコモザイクウイルス Tm-2 型抵抗性</u> 、 <u>タバコモザイクウイルス Tm-2a 型抵抗性</u> 、 <u>疫病抵抗性</u> 、 <u>褐色根腐病抵抗性</u> 、 <u>斑点病抵抗性</u> 、 <u>斑葉細菌病抵抗性</u> 、 <u>青枯病抵抗性</u> 、 <u>かいよう病抵抗性</u> 、 <u>輪紋病抵抗性</u> 、 <u>TYLCV-イスラエル系統抵抗性</u> 、 <u>TYLCV-マイルド系統抵抗性</u> 、 <u>TSWV 抵抗性</u> 、 <u>Leveillula(Oidiopsis) 菌によるうどんこ病抵抗性</u> 、 <u>Oidium 菌によるうどんこ病抵抗性</u>
遺伝子	<u>回復遺伝子の有無</u> 、 <u>標識遺伝子の有無</u>

[†] 生育診断の指標としても用いられる形質

[‡] 定量的かつ連続的な変化を示すにも関わらず、専門家の目視観察によって定性的に評価される形質

が顕著に現れることが知られており、トマトの生育状態を診断するうえで重要な指標の1つとされている。しかし基本的に、節間距離の計測は個体ごとに農家や育種家の目視観察によって行われるため、計測にかかる作業コストが大きいことが問題とされてきた。そのため、節間距離の自動計測技術が確立されることは、育種開発と栽培管理の両方において大きな意義を持つ。このような理由から、本研究では節間距離を計測対象の1つとして選んだ。また、従来の目視観察による評価と同様、節間距離の計測は非破壊で行われる必要があることも、節間距離を計測対象として選んだ理由の1つである。画像解析によって節間距離の計測を自動化するうえで大きな課題となるのが、いかにして樹体画像から節領域を抽出するかである。特にトマトでは、生育に伴って樹体の様相がダイナミックに変化することから、従来の閾値処理を要するような画像解析手法を適用する場合、トマトの生育段階に応じた閾値調整が問題となる。本研究では、画像解析と機械学習を組み合わせ、従来ではユーザーによって調整されていた閾値を判別モデルによって自動で推定することで、この問題の解決に取り組む。

次に、着果期以降では、果菜類における重要な育種形質の1つである着果数の自動計測に取り組む。日々の着果数の推移は、作物の収量ポテンシャルを推定するうえで重要な情報であると考えられる。また、栽培の観点からは、圃場内における着果数の分布を正確に把握することで、栽培管理や収穫作業にかかる労働コストの削減や、肥料、農薬などの使用量の最適化などが期待できる。加えて、生育段階別の着果数を計測することができれば、長期的な経営戦略を練るうえで重要となる収量変動の予測も可能となる。しかし、他の形質と同様に人力による計測方法に頼っていることが計測頻度の制限となっていた。こうした理由から、着果数の自動計測技術が確立されれば、育種、栽培の両方で大きな貢献が期待できる。画像解析によって着果数を推定するためには、樹体画像から果実領域を抽出する必要があるが、ここでも樹体の生育段階に伴った閾値調整が課題となる。また、熟果に関しては他の器官にはない唯一の色彩特徴を有することから画像解析による抽出が比較的容易であり、そのため収穫ロボット関連の研究において多くの抽出手法が開発されてきた [6, 61, 83, 196]。その一方で、幼果や未熟果は茎などの器官と類似した色彩特徴であることに加え、とりわけ幼果に関しては果実自体が小さいことから、画像解析による抽出が困難であるとされてきた。本研究では、画像解析と機械学習を組み合わせることで閾値調整と幼果、未熟果検出の2つの課題の解決に取り組む。

収穫後の果実では、表 1.1 に示した果実に関する計測項目の中から、完熟期における果実の色彩、形状、大きさを定量的に評価するための画像解析手法を開発する。とりわけ果実の色彩と形状については、定量的かつ連続的な変化を示す形質であるにも関わらず、専門家の目視観察によって定性的に評価されている現状にある。そのため、評価者が作業経験の積み重ねによって獲得した判断要因や判

断基準に頼ることが多く、客観性や定量性に欠けることが問題視されてきた。このような問題を解決すべく、本研究では、画像解析を用いることで、従来の評価指標を代替する定量的かつ客観的な外観特徴の評価手法や評価指標の開発に取り組む。

本研究の最後には、開発技術の総合評価を行った上で、今回は計測対象としなかった表現型の自動計測に向けた応用性について考察する。また、今回の成果を足がかりとして今後、作物の表現型を網羅的に自動計測するためのシステムへと発展させる上での課題についても検討する。

1.3 本論文の構成

1章では、育種面と栽培面の2つの観点から見た研究背景について述べ、本研究の目的を明確にした。

2章では、トマトの生育初期における重要な生育指標の1つである本葉の節間距離に着目し、画像解析を用いたトマト樹体画像からの節検出、および節間推定に取り組む。作物は生育段階や生育状態によって様相が大きく変化するため、異なる個体、あるいは同じ個体でも生育段階の異なる樹体の画像に対して同じ手法を適用する場合には閾値の調整が必要となるが、本研究では画像解析と機械学習を組み合わせて用いることで、この課題の解決に取り組む。さらに、時系列の節検出結果をあわせて解析することで、節間距離推定の精度向上を図る。

3章では、果菜類における最も重要な形質の1つとしてあげられる収量の自動計測を目的とし、画像解析を用いたトマト樹体画像からの果実検出に取り組む。2章と同様、開発手法に機械学習を組み合わせることで、閾値調整の問題解決に取り組む。さらに、外観特徴上の問題から検出が難しく、既往研究においても検出対象とされてこなかったトマトの幼果の検出にも挑戦し、開発手法を用いた長期的な収量変動の予測への利用可能性について考察する。また、開発手法をトマト栽培ベッドのパノラマ画像に適用することで、開発手法を用いた圃場の収量マップ生成の可能性を示す。

4章では、収穫後のトマト果実の外観特徴を定量的に評価するための技術を開発する。従来、農産物の外観特徴の評価は専門家の目視観察によって行われてきたものの、そこには客観性や定量性の問題が存在した。加えて、育種開発の場面では、果実の外観特徴の評価に定性的な指標が用いられていたため、外観特徴の微細な変化に関する情報が失われてしまっていた。そこで本研究では、農産物の色彩、形状、サイズといった外観特徴を画像解析によって定量的に評価するための技術を開発し、従来の定性指標を定量値で表すことに取り組む。さらに、得られる特徴量を用いて品種間の外観特徴上の関係を定量的に評価することで、開発手法の品質評価や育種開発への利用可能性について考察する。

最後に、5章では、本研究の成果をまとめた上で、現段階における開発手法の問題点を明らかにし、本研究の成果を足がかりとした作物表現型の総合解析システムへの発展に向けた今後の展望について述べる。

第 2 章

生育初期におけるトマト樹体画像からの節検出および節間距離推定

2.1 はじめに

トマトでは、苗段階での生育状態がその後の果実の肥大、ひいては収量に大きな影響を及ぼすとされている [207, p.80]。そのため、トマトの生育初期における生育状態は重要な育種形質であり、それを的確に診断することは栽培面においても重要な役割を担う。従来、トマトの生育状態の評価は専門家の目視観察によって行われており、計測に要する時間や精度の問題が生じてきた [191]。そのため、精密農業の実現や形質評価の高速化の観点からも、初期段階での生育状態を正確かつ高速に自動計測することは重要性が高いと言える。

作物の生育評価は非破壊、非接触で行われることが望ましく、そのためこれまでも画像解析を用いた研究事例がいくつか報告されている。苗の生育評価に画像解析を用いた最初の例として、Rigney and Kranzler [147] による研究があげられる。著者らの研究では、コンベア上を流れるマツ苗の主茎の太さやシュートの高さ、根の体積を画像解析によってリアルタイムで計測し、苗の等級付けを行っている。また、Bai et al. [7] と Xian et al. [178] によって提案された球果植物の苗の評価システムでは、根とシュートの結合部分の直径やシュートの高さ、根とシュートの投影面積など、計 12 種類の形態的特徴を画像解析によって評価している。最終的な苗の等級付けには、得られた特徴量のニューラルネットワークによる機械学習を用いている。また、画像解析を用いてトマト苗の生育評価を行った研究事例もいくつかある。Ling and Ruzhitsky [100] はトマト苗の樹冠投影面積を画像解析により計測している。樹冠投影面積を計測するためにはトマト苗が写った画像から背景部分を除去する必要があるが、この処理には大津の二値化法 [128] を用いている。近年の研究例では、Tong et al. [168] がセルトレイに植えられたトマト苗群から個々の苗の葉面積計測に取り組んでいる。著者らの研究で

開発された手法では、隣り合う苗の葉が接触している場合でも、Watershed と呼ばれる画像分割手法を適用することで個々の苗を抽出できることが確認されている。

上述の既往研究では、生育初期におけるトマト樹体の生育指標として葉面積が用いられているが、従来のトマト苗の生育評価では、その他にも本葉の節間や茎の太さ、草姿などが生育指標として用いられている [211, 227]。とりわけ本葉の節間には、環境ストレスの影響が顕著に現れることが知られており、節間が長いときには高夜温や日照不足、窒素過剰など、反対に節間が短い場合は低夜温や水分不足などの原因が考えられる [207, p.85]。生育診断における節間距離の重要性はトマト以外の作物でも同様であり、そのためこれまでも画像解析を用いた節検出や節間距離推定に関する研究がいくつか行われてきた。Davis [33] は、菊の樹体のシルエット画像に対してリングオペレータを適用し、得られた特徴量をニューラルネットワークで学習することで節領域を検出することに成功している。門田ら [212] は、サツマイモ苗の画像にフィルタ処理などを適用することで、主茎と葉柄の領域だけを抽出することに成功している。また、抽出領域の交点を節位置として用いることで、穂木切取に適した苗の切断位置を推定している。Mohammed Amean et al. [114] は、ハイビスカス苗の画像から Vesselness measure と呼ばれる形状特徴とハフ変換などを用いて節領域を抽出している。また、McCarthy et al. [110] は同様の手法を、実圃場で移動しながら撮影した棉の木の動画に適用している。著者らは、隣接する樹体の節検出結果を併せて解析することで、検出節の節位を推定しており、またその結果を用いて個々の樹体における節間距離を推定している。しかし、正確に推定できた節間距離は全体の 11% 程度であり、まだまだ改善の余地がみられる。このように、トマト以外の作物では、画像解析を用いた節検出および節間距離推定に関する研究がいくつか行われているものの、トマトに関してはこういった研究事例が存在していない。

本研究では、トマト樹体の生育初期段階における自動生育診断を目的とし、画像解析を用いた節間距離の推定技術の開発に取り組んだ。開発手法は節検出、節位推定、節間距離推定の 3 段階の処理によって構成される。まず節検出処理では、画像特徴量の機械学習によってトマト樹体画像から節領域を抽出する。次に、節位推定処理では検出した節領域の節位を Affinity Propagation と呼ばれるクラスタリング手法を用いて推定し、最後にその結果から節間距離を推定する。開発手法が有する特徴として、(1) 画像特徴量の機械学習によって節領域を判定するため、画像特徴量に対して閾値を調整する必要がない、(2) Affinity Propagation を用いるため、最終的な節数が異なる時系列のトマト樹体画像に対しても適用可能であるということがあげられる。本研究では、複数株の時系列トマト樹体画像に対して開発手法を適用し、節検出および節間距離推定の精度を検証するとともに、開発手法のトマト生育診断への利用可能性について考察した。

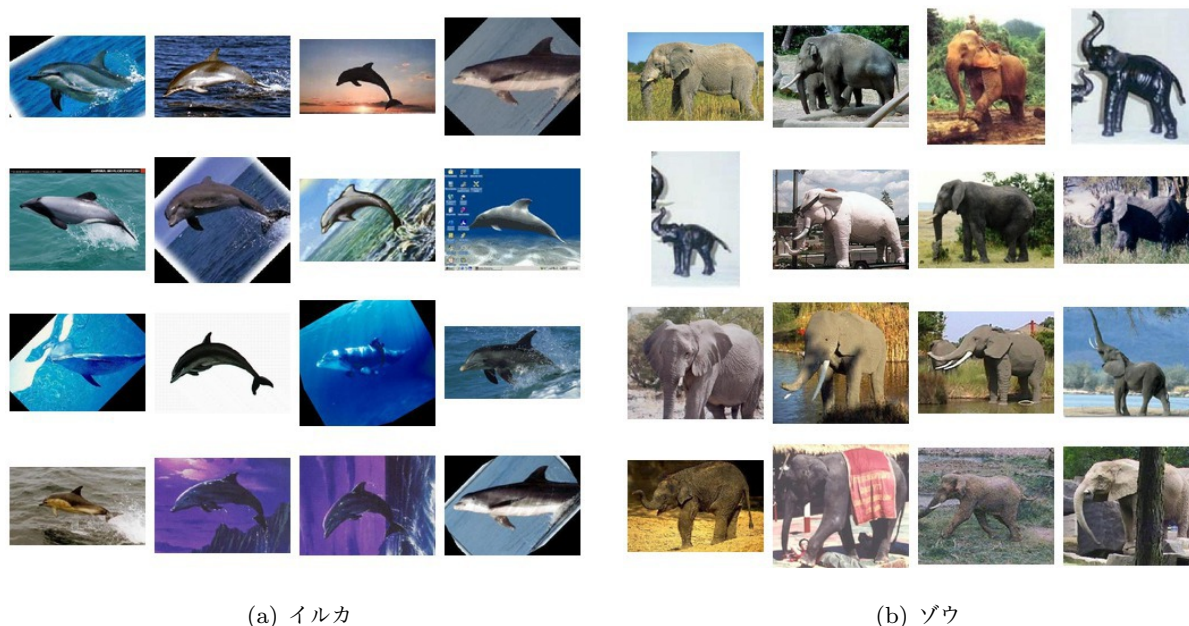


図 2.1 一般物体認識で用いられる画像例。Caltech-101 画像データベース [39] から引用。

2.2 節検出および節間距離推定手法

2.2.1 一般物体認識

実世界シーンにおいて撮影された画像から、その画像中に存在する物体をコンピュータによって認識することを一般物体認識 (Generic Object Recognition) という [236]。一般物体認識において解析対象とされる画像の例を図 2.1 に示す。同図では撮影環境や被写体に多少の違いはあるものの、図 2.1(a) はイルカ、図 2.1(b) はゾウの写真であると人間であれば容易に判断できる。人間は数万種類の対象を認識できると言われる一方で [10]、このような認識をコンピュータで行うことはまだまだ難しく、画像認識の研究において最も困難な課題の 1 つであると考えられている [236]。

近年、一般物体認識に関する技術は急速な発展を遂げてきた。それはコンピュータの計算能力の向上のみならず、優れたアルゴリズムが開発されてきたことにも起因する。もっとも典型的な一般物体認識の処理は、以下に示す 3 つのステップによって構成される [22]。

画像からの局所特徴量の抽出

一般物体認識に用いられる画像は見た目の多様性が極めて大きいため、計算する特徴量は画像のノイズや部分的なオクルージョン^{*1}、照明変化、視方向、スケールなどに対して不変性を有することが求められる。これらの要件を満たすためには、まず、画像のどの領域で特徴量を計算するかが重要となる。Scale-Invariant Feature Transform (SIFT)[108] や Speeded-Up Robust Features (SURF)[8]、Harris[56]、Features from Accelerated Segment Test (FAST)[148]、Maximally Stable External Regions (MSER)[109]、Harris[56] などの特徴点検出手法では、画像中の輝度変化をもとに物体認識において重要な特徴を有する領域を決定し、その領域だけで特徴量を計算する。一方で、Dense Sampling と呼ばれる手法では、画像中を等間隔に区切って全ての領域で特徴量を計算する。ただしこの場合、物体認識には関係のない背景部分でも特徴量を計算するため、計算コストが高いうえに誤認識の原因ともなりうる。特徴量を計算する領域を決定した次に重要となるのが、その領域でどのようにして上述の不変性を満たす特徴量を計算するかである。特に、特徴点まわりの領域を画素値や微分値により特徴ベクトル化したものを局所特徴量と呼び [219]、SIFT[108]、SURF[8]、ORB[149]、BRISK[95] など、これまでに多くの特徴量が開発されている。

局所特徴量の符号化

画像から抽出した局所特徴量によって認識物体を表現する手法として、Bag of Features（または、Bag of Keypoints、Bag of Visual Words、以下、BoF）[31] が広く用いられている。BoF は、統計的自然言語処理における Bag of Words[92] を基本とする。Bag of Words で語順を無視して文章を単語の集合として扱うのと同様、BoF では画像中の位置を無視して画像を局所特徴量の集合として扱う [236]。そのため、得られる特徴量は画像の平行移動や回転移動、拡大・縮小などに対して不変性が確保される。

実際の処理の流れを学習過程、検証過程に分けて図 2.2 と図 2.3 に示す。学習用画像から特徴点を抽出して局所特徴量を計算し、 k -means 法 (2.2.2 項参照) などによるクラスタリングを適用する。このとき得られる各クラスターの平均ベクトルを Visual word と呼ぶ。次に、学習用画像の各特徴点から計算された局所特徴量に最も近い Visual word に投票していくことで、画像を Visual word ヒストグラムとして表現する。検証用画像についても同様の処理を行い、Visual word ヒストグラムを生成する。

^{*1} 手前にある物体が背後にある物体を隠している状態

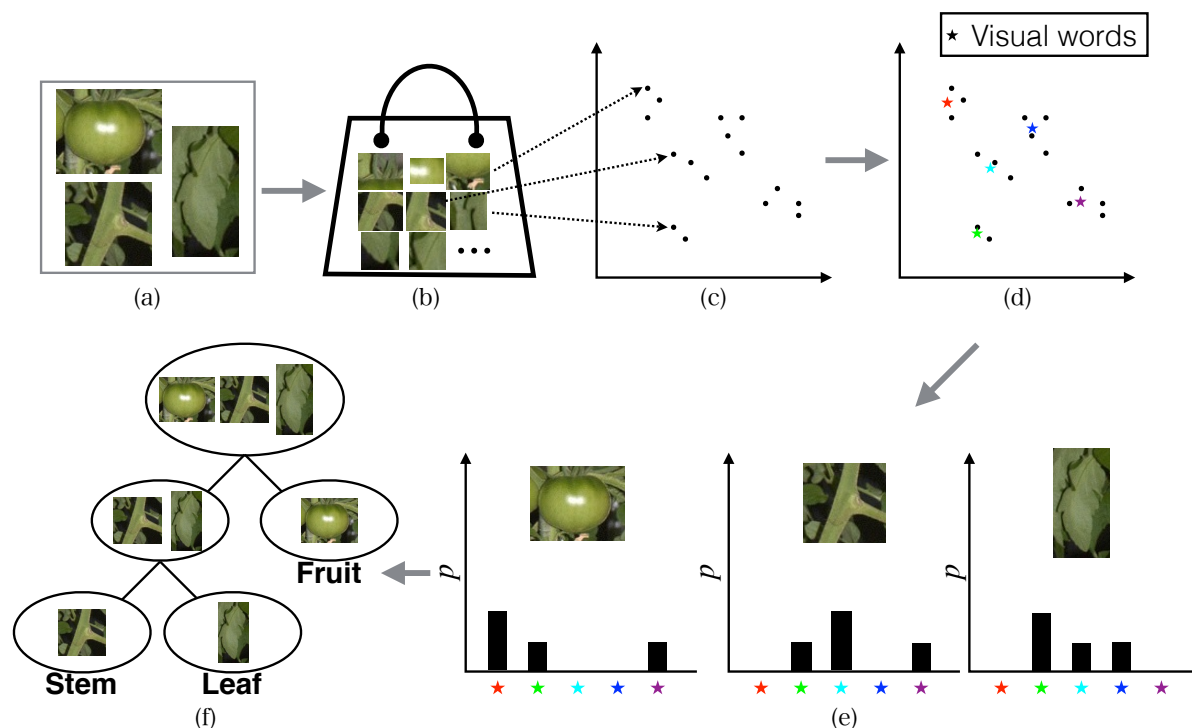


図 2.2 学習過程における BoF の概略図

- (a) 学習用画像
- (b) 特徴点周りの領域を抽出
- (c) 局所特徴量を計算してプロット
- (d) k -means 法によるクラスタリング。各クラスターの平均ベクトルを Visual word とする
- (e) 各画像で計算した局所特徴量に最も近い Visual word に投票してヒストグラムを生成
- (f) ヒストグラムを基に予測モデルを生成

画像記述子の機械学習

検証用画像の Visual word ヒストグラムに対して機械学習を適用することで、物体認識のための予測モデルを生成する。次に、未知の物体が含まれる検証用画像から生成した Visual word ヒストグラムに対してこの予測モデルを適用することで、検証用画像の中に含まれる物体を認識する。これまでの研究事例では、Support Vector Machine[31, 122, 200]、Artificial Neural Network[75, 76]、Random Forest[13, 117]などの分類器が BoF で多く利用されている。

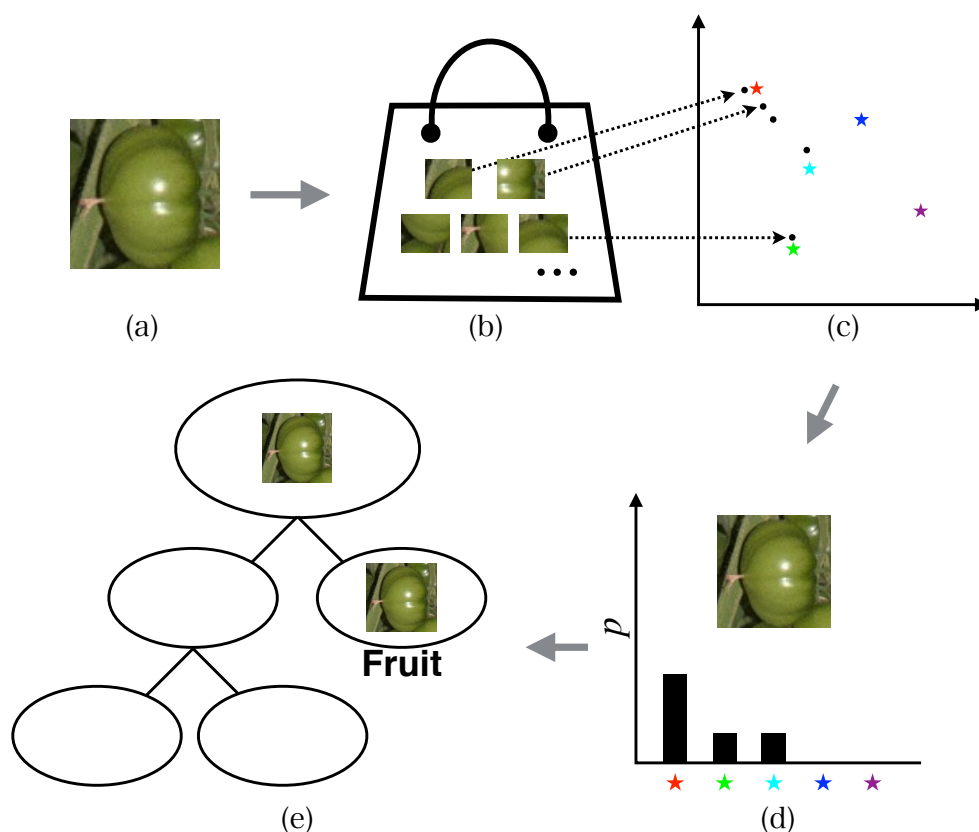


図 2.3 検証過程における BoF の概略図

- (a) 検証用画像
- (b) 特徴点周りの領域を抽出
- (c) 局所特徴量を計算してプロット
- (d) 各局所特徴量に最も近い Visual word に投票してヒストグラムを生成
- (e) 生成した予測モデルによって検証用画像の属するクラスを求める

2.2.2 k -means 法

クラスタリングは、データセットの中のデータ点をいくつかのクラスタに分ける手法であり、似たデータが同じクラスタに属するように計算される。クラスタリング手法は、階層的クラスタリングと非階層的クラスタリングの2つに大別される。このうち、非階層的クラスタリング手法の代表例としてあげられるのは、Hartigan and Wong [57] によって提案された k -means 法である。 k -means 法の計算手順を以下に示す。

1. データセットの中から k 個のクラスタ中心をランダムに選択する。
2. データセットの全てのデータ点と k 個のクラスタ中心との距離を計算し、最も距離が小さいク

ラスタ中心に属させる。

3. 生成された各クラスタの中心点を求める。
4. 以下の条件のいずれかを満たすまで、2-3 を繰り返す。
 - (a) 指定回数以上の繰り返し
 - (b) 指定値より小さい変化量
 - (c) 全データセットのクラスタ割り当てに変化がない

このように比較的単純なアルゴリズムであるにも関わらず、良好な結果が得られることから、 k -means 法は幅広い分野で使われてきた。一方で、 k -means 法にはいくつかの欠点がある。まず、 k -means 法によるクラスタリング結果は、ランダムに決定されるクラスタ中心の初期値に大きく依存するということがあげられる。そのため、一般に k -means 法を用いる場合、同じデータセットに対して k -means 法を複数回適用し、もっとも良い結果を用いるようにする必要がある。また k -means 法では、クラスタ数を入力パラメータとして与える必要がある。そのため、正確なクラスタ数が未知であるデータセットの場合、 k -means 法を適用することは難しい。

2.2.3 Affinity Propagation

k -means 法の問題を解決した手法として、Frey and Dueck [44] によって提案された Affinity Propagation がある。 k -means 法と比較して、Affinity Propagation は、(1) クラスタ中心の初期値をランダムに設定する必要がなく、安定したクラスタリング結果が得られるため、複数回実行する必要がない、(2) データセットの分布に応じて最適な分割クラスタ数が計算によって求められるといった利点を有する。

Affinity Propagation では、データセットの全データ点間で2種類のメッセージが交換される。1つは「責任度 (Responsibility)」と呼ばれるデータ点 i からクラスタ代表 (exemplar) の候補データ点 k に向けて送られるメッセージであり、「データ点 i がデータ点 k を代表とするクラスタに割り当てられる適切度」を表す。もう1つは「可用性 (Availability)」と呼ばれるクラスタ代表の候補データ点 k からデータ点 i に向けて送られるメッセージであり、「データ点 k を代表とするクラスタにデータ点 i が割り当てられる適切度」を表す。Affinity Propagation の計算手順を以下に示す。

1. 式 (2.1) により、データ点 i (x_i) とデータ点 k の (x_k) の距離 $s(i, k)$ を求める。ただし、 $s(k, k)$ は「嗜好度 (Preference)」と呼ばれるパラメータであり、このパラメータによって最終的なクラスタ数の増減を調整する。嗜好度が大きいほど、生成されるクラスタ数が多くなる。

また、嗜好度はデータ点ごとに異なる値を設定することもでき、与える嗜好度が大きいデータ点ほどクラス代表点になりやすくなる。Frey and Dueck [44] は、最適なクラス数を得る嗜好度として、式 (2.2) から得られる中央値を推奨している。

$$s(i, k) = -\|x_i - x_k\|^2 \quad (2.1)$$

$$s(k, k) = \text{median}_{k' \neq k'}(s(k, k')) \quad (2.2)$$

2. x_i と x_k の間の可用性 $a(i, k) = 0$ で初期化する。
3. x_i と x_k の間の責任度 $r(i, k)$ を式 (2.3) で計算する。ただし、 $r(k, k)$ の計算には式 (2.4) を用いる。

$$r(i, k) \leftarrow s(i, k) - \max_{k' \neq k} \{a(i, k') + s(i, k')\} \quad (2.3)$$

$$r(k, k) \leftarrow s(k, k) - \max_{k' \neq k'} \{s(k, k')\} \quad (2.4)$$

4. $a(i, k)$ を式 (2.5) で計算する。ただし、 $a(k, k)$ の計算には式 (2.6) を用いる。

$$a(i, k) \leftarrow \min\{0, r(k, k) + \sum_{i' \neq i'} \max\{0, r(i', k)\}\} \quad (2.5)$$

$$a(k, k) \leftarrow \sum_{i' \neq i'} \max\{0, r(i', k)\} \quad (2.6)$$

5. n 回目の反復処理において算出された $a_n(i, k)$ と $r_n(i, k)$ は、以下の式によって調整される。

$$r_n(i, k) = (1 - \lambda) \times r_n(i, k) + \lambda \times r_{n-1}(i, k) \quad (2.7)$$

$$a_n(i, k) = (1 - \lambda) \times a_n(i, k) + \lambda \times a_{n-1}(i, k) \quad (2.8)$$

ここで、 λ は「減衰係数 (Damping factor)」と呼ばれるパラメータであり、反復処理の中で責任度と可用性が振動するのを防ぐために設定される。 λ は 0 から 1 の間の値を取り、デフォルトでは 0.5 が用いられる。

6. $a(i, k) + r(i, k)$ が最大となる x_k を代表点とするクラスに、 x_i を割り当てる。
7. 以下の条件のいずれかを満たすまで、3-6 を繰り返す。
 - (a) 指定回数以上の繰り返し
 - (b) $a(i, k) + r(i, k)$ の変化量が閾値以下
 - (c) 指定回数以上、割り当てクラスに変化がない

x_k より他に x_i との類似度が大きいデータ点が存在しない時、 x_k は x_i が属するクラスの代表点になるべきであると考えられるため、 $r(i, k)$ は大きくなる (式 (2.3)、図 2.4)。また、 $r(k, k)$ は

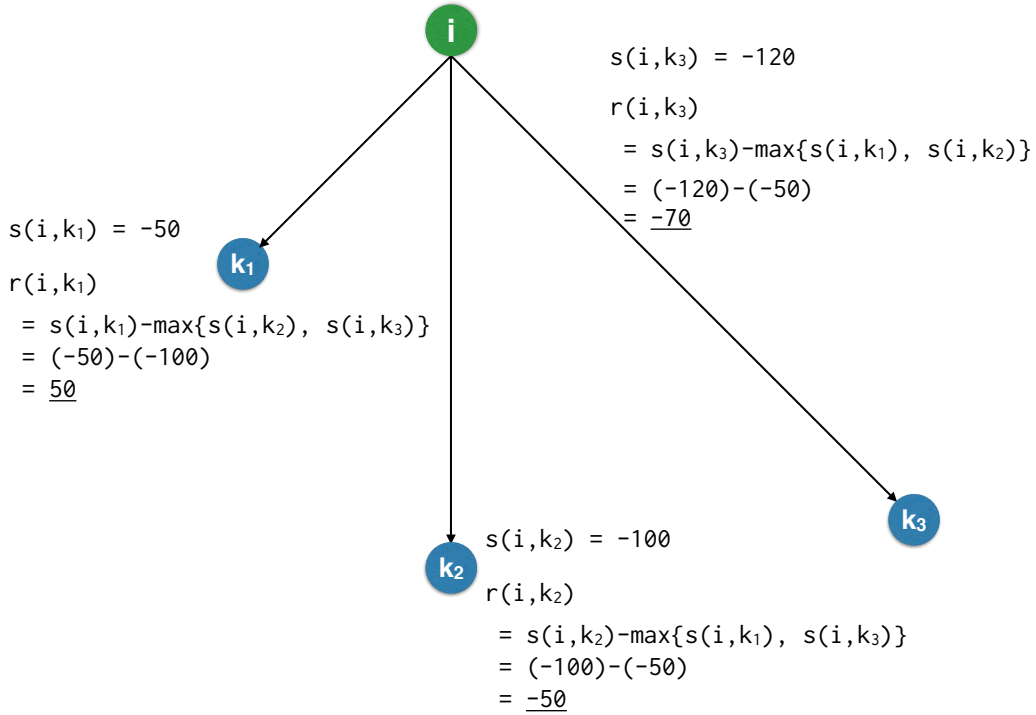


図 2.4 データ点 x_i と 3 つのクラスタ代表候補点 $x_{k_1}, x_{k_2}, x_{k_3}$ との間の責任度。 x_i に最も近いデータ点は k_1 、最も遠いデータ点は k_3 であるため、責任度は $r(i, k_1) > r(i, k_2) > r(i, k_3)$ となる。

「自己責任度 (Self-responsibility)」と呼ばれ、 x_k がクラスタ代表点になる適切度を表す。嗜好度である $s(k, k)$ の値が大きいほど、 $r(k, k)$ が大きくなり、結果として x_k がクラスタ代表点になりやすくなる。また、 x_k にもっとも近いデータ点との類似度が x_k の嗜好度と比較して小さい (x_k の近くにデータ点が存在しない) 場合、 x_k はクラスタ代表点になるべきであると考えられるため、 $r(k, k)$ は大きくなる。

式 (2.5) から得られる $a(i, k)$ は、 x_k の自己責任度と、 x_i 以外のデータ点から x_k に送られる正の責任度の総和によって算出される。他のデータ点から送られる正の責任度の過度な影響を制限するために、 $a(i, k)$ は 0 より大きい値を取らないようにしている。また、 $a(k, k)$ は「自己可用度 (Self-availability)」と呼ばれる、 x_k のクラスタ代表点としての適切度を表す指標であり、他のデータ点から x_k に向けて送られる正の責任度の総和によって算出される。

2.2.4 節検出手法

本研究で開発した節検出手法は 4 段階の処理で構成される。開発手法のフローチャートを図 2.5 に示す。以下、開発手法の概要を段階を追って説明する。

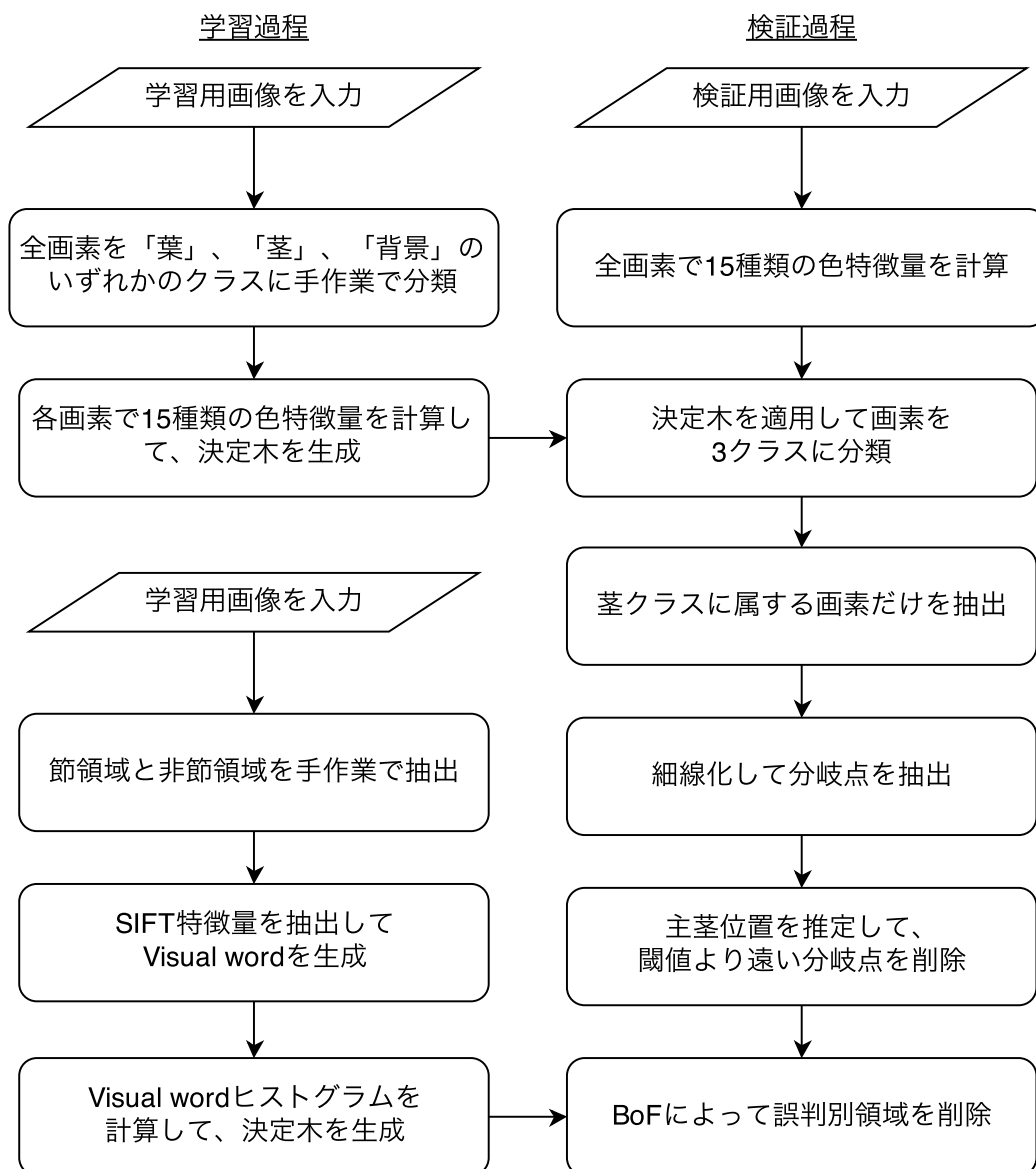


図 2.5 節検出手法のフローチャート

最初に実行されるのは、色特徴量の機械学習による画素単位での画像分割である。この処理は、Guo et al. [53] によって提案された Decision Tree based Segmentation Model (DTSM) に基づいて実行される。学習過程では、学習用画像の各画素を茎、葉、背景の3クラスに手作業で分類し、分類した画素から5種類の色空間 (RGB, HSV, $L^*a^*b^*$, $L^*u^*v^*$, YCbCr) で定義される15種類の色特徴量 ($r, g, b; H, S, V; L^*, a^*, b^*; L^*, u^*, v^*; Y, Cb, Cr$) を計算する。この作業には、選択画素とその8近傍画素の色特徴量とラベル情報 ("leaf", "stem", "background") が自動記録できる GUI アプリケーションを用いる (図 2.6)。また、色特徴量の計算には OpenCV 2.4.9 [68] 内の `cvtColor`



図 2.6 GUI アプリケーションによる学習データ抽出。画像上をドラッグすることで学習に用いる画素を選択できる。選択された画素のうち、緑は葉クラス、紫は茎クラス、青は背景クラスの学習データとしてそれぞれ用いられる。

関数を用いる。なお、今回用いた色空間についての詳しい説明は付録 A を参照されたい。最後に、抽出した色特徴量とラベル情報から Classification And Regression Tree (CART) [14] に基づく決定木を生成する。CART では、入力変数として用いた 15 種類の色特徴量の中から、入力データのラベル予測に重要な変数が自動で選択される。次に、検証過程では検証用画像の各画素で色特徴量を計算し、学習過程で生成した決定木を適用することで検証用画像の各画素を上述の 3 クラスのいずれかに分類する。

次段階の処理では、節候補点を抽出する。上述の処理で茎画素と判定された画素の画素値を 1、それ以外を 0 とした茎画像を生成する (図 2.7)。生成された茎画像に対して細線化処理を施し、分岐点を抽出する (図 2.8)。この処理によって抽出された分岐点を節候補点として以降の処理に用いる。

上述の処理により抽出された節候補点には、実際の節の位置に対応しない点が多く含まれる。以降の処理はこうした誤検出点の削除を目的として実行される。まず、茎画像に対してラベリング処理を施し、最も y 軸方向の長さが大きい連結領域に属する画素のみを抽出する (図 2.9(b))。次に、抽出した画素の x 座標を説明変数、 y 座標を目的変数として線形回帰を行い、得られた直線を主茎のおおまかな位置を表す主茎直線として用いる (図 2.9(c))。最終的な検出対象である本葉の節は主茎上のみ存在するため、推定された主茎直線から x 座標上の距離が閾値より遠い節候補点を誤検出点とし

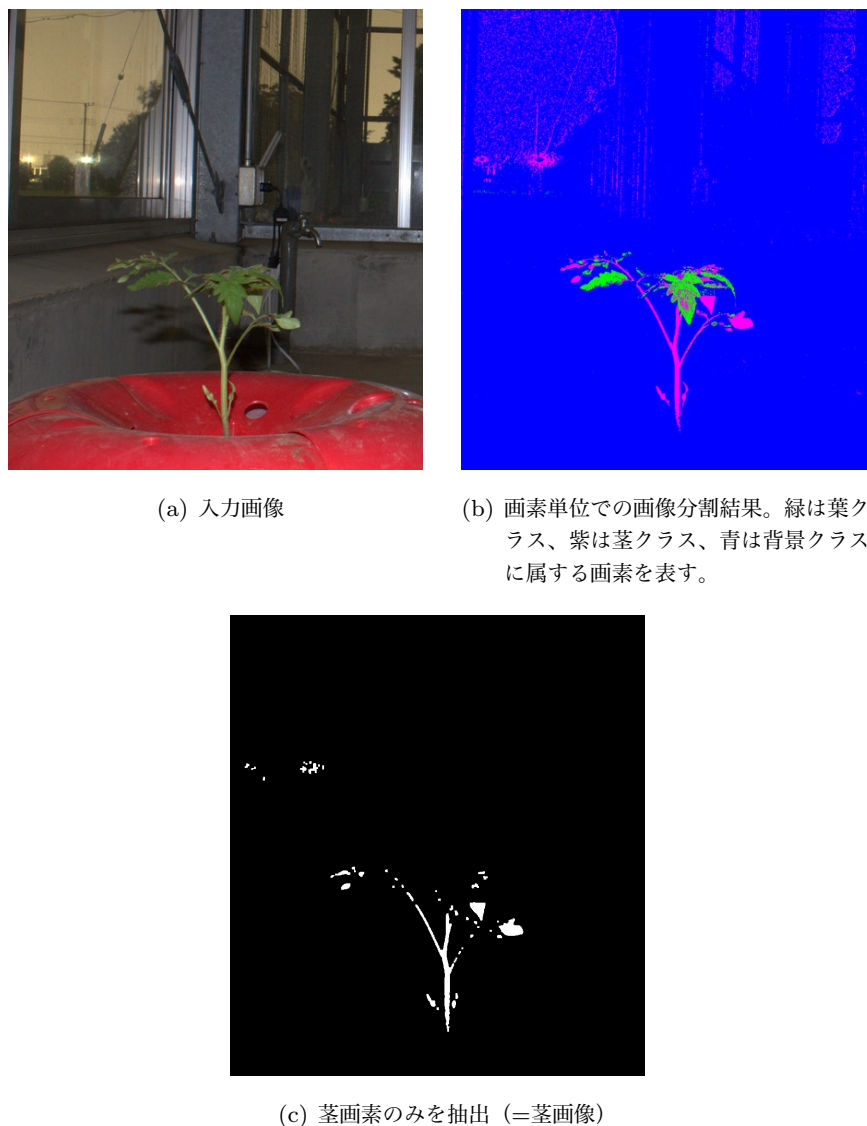


図 2.7 茎画像の生成例

て削除する (図 2.9(d))。

上述の処理によっておよそ誤検出点が削除されるものの、主茎近辺で発生した誤検出点は削除できない。そこで、開発手法では最後に Bag of Features と呼ばれる一般物体認識手法を用いて残った誤検出点を削除する (2.2.1 項参照)。まず学習過程では、学習用画像から節周辺の領域とそれ以外の領域を手動で抽出する。次に、抽出した節領域画像および非節領域画像から Bag of Feature の手法に基づいて Visual Word ヒストグラムを生成する。最後に、生成した Visual Word ヒストグラムを用いて Random Forest[15] 法に基づく決定木を生成する。検証過程では、検証用画像から抽出された節候補点の周囲 n 近傍の画素を含む領域を抽出して Visual Word ヒストグラムを生成し、学習




図 2.8 節候補点の抽出例

過程で生成した決定木を用いて節領域であるかどうかを判定する。最後に、節領域として判定された領域の重心 y 座標をその画像内に存在するトマト株の垂直方向の節位置として用いる。なお、開発手法では特徴点の抽出にコーナー検出に用いられる Harris 検出器 [56] を採用した。その理由は、節周辺にはコーナー点が多く存在しており、Harris 検出器を用いることで節周辺で多くの特徴点を抽出できることが予備実験において確認されたためである。また局所特徴量の計算には、既往研究において一般物体認識におけるその有用性が確認されている SIFT[108] を用いた。




図 2.9 主茎検出および節候補点削除の例

2.2.5 節位推定手法

時系列トマト樹体画像に対して節検出手法を適用すると、図 2.11(a) に示すような結果が得られる。本研究の最終的な目的は隣り合う 2 つの節の節間距離の推定であるが、同図に示す結果では未検出節や節位置の誤推定が発生しており、任意の時間における検出節が第何節に属するのかの判断が難しい。正確な節間距離を推定するためには、検出節の節位を推定したうえで未検出節の補間、および誤推定された節位置の削除が必要となる（図 2.10）。そこで本研究では、Affinity Propagation と呼ばれるクラスタリング手法（2.2.3 項参照）と回帰分析を用いて検出節の節位を推定する。




図 2.10 節間距離の誤推定例

節位推定手法の概略図を図 2.11 に示す。開発手法では、まず図 2.11(a) に示す時系列画像の節検出結果から日時情報を削除する (図 2.11(b))。次に、その結果に対して Affinity Propagation によるクラスタリング処理を適用し、 n 個のクラスタに分類する (図 2.11(c))。各クラスタにおける代表点の y 座標値が大きい順に、属する検出節を第 1 節から第 n 節とする。最後に、日時情報を戻して日時情報を説明変数、検出節の y 座標を目的変数とした回帰分析をクラスタごとに実行することで、時系列上における各節の y 座標方向 (垂直方向) の位置を推定する (図 2.11(d))。Affinity Propagation では、入力データの分布に応じて最適な分割クラスタ数が計算によって求められるが、今回の場合には、その分割クラスタ数がトマト株の最終的な節数と一致する。そのため、開発手法では解析に用いる株の節数が様々である場合でも、その節数をパラメータとして与える必要がなく、自動で推定されるという特徴を有している。


2.2.6 節間距離推定手法

開発した節位推定手法により、時系列上での各節の垂直方向の位置を表す直線が得られる (図 2.11(d))。本研究では、これらの直線を節直線と呼ぶこととする。任意の時間における第 n 節の節直線と第 $(n+1)$ 節の節直線との間の y 座標上の距離を、2 節間の推定節間距離として用いる。ただし、任意の時間において第 $(n+1)$ 節がすでに発生している場合にのみ節間距離を計算する。


2.3 解析試料および方法

2.3.1 画像取得


撮影に用いたトマトは、東京大学 大学院 農学生命科学研究科付属 生態調和農学機構内の温室にて栽培した。栽培には、市販の水耕栽培キット (ハイポニカ、協和株式会社、大阪) を用いた。撮影に




(a) 時系列画像からの節検出結果。横軸は撮影日時、縦軸は検出節の y 座標を表す。



(b) 節検出結果から日時情報を削除



(c) Affinity Propagation によるクラスタリング結果



(d) 日時情報を戻してクラスごとに線形回帰

図 2.11 節位推定手法のながれ

表 2.1 解析に用いたトマト株の品種、播種日、撮影期間および撮影画像数

	品種	播種日	撮影期間	撮影画像数
トマト株 A	ハウス桃太郎	2014 年 6 月 19 日	7 月 9–16 日	36
トマト株 B	ハウス桃太郎	2014 年 7 月 23 日	8 月 18–26 日	43
トマト株 C	ハウス桃太郎	2014 年 6 月 19 日	7 月 2–10 日	35

は一眼レフカメラ（EOS 60D, Canon Inc., 東京）を用い、外光による影響の少ない時間帯として 0 時、2 時、4 時、20 時、22 時に撮影を行った。解析に用いたトマト株の品種と播種日、撮影期間、撮影画像数を表 2.1 に示す。

2.3.2 機械学習手法のパラメータ決定

機械学習の判別性能は、パラメータの設定値に大きく依存する。開発手法では、画素単位での画像分割で CART、Bag of Features に基づく誤判別削除で Random Forest、検出節の節位推定処理で Affinity Propagation という 3 種類の機械学習を用いたため、それらのパラメータの決定方法について述べる。なお、本研究では、全ての機械学習に基づく計算処理に、R version 3.1.0 [143] を用いた。

CART における主要なパラメータとして、剪定を行う木の深さがあげられる。例えば、剪定を行う深さが深すぎる場合、生成される決定木は与えられた学習用データの判別に特化したものになってしまい、検証用データの判別精度が低下することがある。これを、過学習、あるいはオーバーフィッティングという。本研究では、このパラメータを決定するために、学習用データを用いて 10 分割交差検証を行い、誤判別率が最小となる分岐数のときの誤判別率の平均と標準偏差を足した値（以下、 $\text{Min} + 1\sigma$ 値と呼ぶ）を算出した。そして、分岐数を 0 とした時と比較した相対誤判別率が $\text{Min} + 1\sigma$ 値を初めて下回る分岐数を求め、この分岐数と一致するように学習用データから生成した決定木を剪定した。なお、CART に基づく決定木の生成と剪定パラメータの決定には、mvpart パッケージ*2の rpart 関数と plotcp 関数を用いた。

Random Forest では、作成する決定木の数と、各決定木を作成する際に使用する特徴量の数が重要なパラメータとなる。本研究では、可能性のあるパラメータを全ての組み合わせで実行し、もっとも良い結果が得られたパラメータを用いる方法（グリッドサーチ）によって Random Forest のパラメータを決定した。Random Forest に基づく決定木の生成とパラメータの決定には、randomForest

*2 <http://cran.r-project.org/web/packages/mvpart>

表 2.2 各トマト株から抽出した学習データ数

	トマト株 A	トマト株 B	トマト株 C
正例（節領域）	212	191	211
負例（背景領域）	242	286	255

パッケージ^{*3}の tuneRF 関数を用いた。

Affinity Propagation では、距離行列の対角成分の値である嗜好度と、反復処理において伝播値を調整する減衰係数が重要なパラメータとなる。本研究では、嗜好度には距離行列の 0.2 クォンタイル、減衰係数は Frey and Dueck [44] が推奨している値である 0.5 を用いた（2.2.3 項参照）。

2.3.3 性能評価

開発した節検出手法では機械学習を用いるため、取得した画像を学習用と検証用の 2 つに分ける必要がある。本研究では、取得した 3 株のトマト樹体画像のうち、2 株を学習用、1 株を検証用とし、これを全株が 1 回ずつ検証用となるようテストを繰り返す Leave-one-out 法による交差検定を行った。表 2.2 に各トマト株から抽出した学習データ数を示す。また、節検出の性能評価には、以下に示す 2 つの指標を用いた。

$$\text{Recall} = \frac{\text{画像解析によって検出できた節領域数}}{\text{画像中に存在した節領域数}} \quad (2.9)$$

$$\text{Precision} = \frac{\text{実際の節領域に対応する検出領域数}}{\text{検出領域数}} \quad (2.10)$$

Recall は画像中に存在した節のうち、開発手法によって検出できた節の割合を表す。また Precision は、開発手法によって検出した全領域のうち、手動で設定した節領域に対応する検出領域の割合を表す。

解析に用いた画像の撮影時間と同じ時間において、開発手法を用いた節間距離推定を行った。また、手動で設定した節領域間の重心 y 座標の距離を実節間距離として用いた。それぞれのトマト株において第 n 節と第 $(n+1)$ 節の平均節間距離を計算し、以下の式により得られる相対誤差を節間距離推定の性能評価の指標として用いた。

$$\text{相対誤差 (\%)} = \frac{|\text{推定節間距離の平均 [px]} - \text{実節間距離の平均 [px]}|}{\text{実節間距離の平均 [px]}} \times 100 \quad (2.11)$$

^{*3} <http://cran.r-project.org/web/packages/randomForest>

2.4 解析結果

2.4.1 節検出

開発手法による節検出の性能評価の結果を表 2.3 に示す。開発手法では、解析に用いた画像内に存在した計 358 の節のうち、73% を検出することができた ($\text{Recall}=0.73$)。また、開発手法によって検出した領域のうち、78% が実際の節領域に対応しており ($\text{Precision}=0.78$)、誤検出の発生率が低いことがわかった。株ごとの節検出結果を比較してみると、株 C で Recall 値が 0.91、Precision 値が 0.90 ともっとも良い結果が得られ、反対に株 B では Recall 値が 0.64、Precision 値が 0.68 ともっとも悪い結果となった。また、節位ごとの節検出結果では、特定の節位で極端に検出精度が異なるような傾向は見られなかった。


主茎からの距離の閾値処理と Bag of Features を適用することで、Precision に大きな改善がみられた。とりわけ Bag of Features の適用によって Precision が 0.41 も改善しており、多くの誤判別点が削除されたことがわかる。一方で、Bag of Features の適用によって Recall が 0.03 小さくなっていることから、実際に節に対応する領域についても誤って削除されてしまっていることがわかる。

2.4.2 検出節の節位推定


開発手法による節位推定の結果を図 2.12 に示す。同図では、横軸が解析画像の撮影日時、縦軸が検出節の y 座標を表す。また、同じ色で表した点および線は、同じ節位に属することを意味する。破線で表した実際の節直線と、実線で表した推定された節直線の差が小さいことから、検出節の節位推定が高精度でなされていることがわかる。

図 2.12 では、任意の節の検出 y 座標が時間によって上下にゆらいでいることが確認できる。とりわけトマト株 A, B の第 1 節では、誤って検出された子葉節もいくつか含まれている。しかし、これらの検出節の線形回帰によって得られた回帰直線はその平均的な値をとるため、最終的には実際の節直線と非常に近い値をとるようになっている。一方で、トマト株 B の第 1 節では、8 月 22 日以降に未検出節が多く発生している。しかし、その前後の時間で正確に節位置が検出されており、回帰直線によってこれらの未検出節が補間されている。このように、開発手法の節位推定では単に検出節の節位推定を行うだけでなく、前後の時間における節検出結果に基づいた誤検出による影響の最小化、および未検出節の補間が可能であることが確認された。


撮影期間内に、トマト株 A, B では第 4 節まで発生したのに対し、トマト株 C では第 5 節まで発生した。一方で、開発手法の節位推定に用いた Affinity Propagation では、データセットの分布に応



(a) トマト株 A



(b) トマト株 B



(c) トマト株 C

図 2.12 実際の節直線と推定された節直線の関係。横軸は日時、縦軸は節の y 座標を表す。 \circ は検出した節、 \times は実際の節の位置を表し、実線は検出節から推定された節直線、破線は実際の節直線を表す。また、同色の点と線は同じ節位に属することを意味する。

表 2.3 節検出の性能評価結果

株	節位	誤判別削除なし		主茎検出		主茎検出 + BoF		総節数
		Recall	Precision	Recall	Precision	Recall	Precision	
A	1	0.72	-	0.72	-	0.61	-	36
	2	0.89	-	0.89	-	0.69	-	36
	3	0.83	-	0.83	-	0.74	-	23
	4	0.64	-	0.73	-	0.64	-	11
	全節	0.79	0.21	0.80	0.42	0.66	0.78	106
B	1	0.67	-	0.65	-	0.60	-	43
	2	0.67	-	0.65	-	0.67	-	43
	3	0.41	-	0.41	-	0.59	-	32
	4	0.67	-	0.50	-	0.50	-	6
	全節	0.63	0.24	0.61	0.35	0.64	0.68	124
C	1	0.94	-	0.94	-	0.94	-	35
	2	1.00	-	1.00	-	0.91	-	35
	3	0.94	-	0.97	-	0.97	-	32
	4	0.68	-	0.68	-	0.79	-	19
	5	0.71	-	0.57	-	0.57	-	7
	全節	0.92	0.17	0.92	0.40	0.91	0.90	128
全株	全節	0.77	0.17	0.76	0.37	0.73	0.78	358

じて最適な分割クラスタ数が自動で設定される。今回の場合、節位推定処理において決定された分割クラスタ数が、トマト株 A とトマト株 C で 4 つ、トマト株 B で 5 つと最終的な節数と一致しており、節数が異なる場合でも正確に節位推定がなされることが確認できた。この結果は、生育にばらつきのある圃場内の複数のトマト樹体画像の解析に対しても、開発手法を適用できる可能性を示唆している。

2.4.3 節間距離推定

それぞれのトマト株における実節間距離と推定節間距離の関係を図 2.13 に示す。同図では、横軸が解析画像の撮影時間、縦軸が節間距離を表し、実節間距離を破線、推定節間距離を直線で表している。また、式 (2.11) から得られる実節間距離と推定節間距離の相対誤差を表 2.4 に示す。全節間距離を対象とした場合、実節間距離と推定節間距離の間の相対誤差は 16.1% 以内に収まっており、開発手法の精度が高いことが示された。一方で、トマト株 B の第 2 節と第 3 節の節間距離の相対誤差

表 2.4 節間距離推定の性能評価結果


株	対象節間	実節間距離（平均） [px]	推定節間距離（平均） [px]	相対誤差 [%]
A	1-2	71.7	77.0	7.4
	2-3	114.3	123.2	7.9
	3-4	58.8	68.8	17.0
	全節間	83.7	90.9	8.7
B	1-2	60.4	61.0	0.9
	2-3	80.3	112.2	39.7
	3-4	133.8	119.6	10.6
	全節間	73.7	85.5	16.1
C	1-2	56.2	58.8	4.6
	2-3	95.7	95.3	0.4
	3-4	84.7	92.4	9.2
	4-5	117.3	118.6	1.1
	全節間	80.2	82.7	3.1

は 39.7% と極端に大きくなった。これは、節検出の段階で子葉節が誤検出されていることに起因する（図 2.12）。Affinity Propagation による節位推定において極端に y 座標が大きい子葉節が第 1 節に含まれてしまったために、8 月 21 日付近において、本来は第 1 節に属すべきであるが比較的 y 座標値の小さい検出節が第 2 節に分類されている。一方で、第 3 節と第 4 節の間には誤検出が多く発生しており、それらが第 3 節のクラスタに含まれてしまっている。その結果として、第 2 節は過大評価、第 3 節は過小評価となり、推定節間距離が極端に大きくなった。


2.5 考察

本研究では、画像解析と機械学習を組み合わせることによって、トマトの節間距離を高精度で推定することができた。筆者らが知る限りでは、本研究が、トマトの節間距離の自動推定技術を開発した初めての研究事例である。開発技術では、全ての処理がコンピュータによって自動的に行われるため、人力による計測に比べて高い効率性を有する。


本研究で開発した節検出手法は、画素単位での画像分割、節候補点検出、主茎検出による誤判別削除、一般物体認識手法による誤判別削除という 4 段階の処理によって構成される。このうち、画素単位での画像分割と一般物体認識手法による誤判別削除は、画像特徴量の機械学習によって生成される分類モデルに基づいて実行される。そのため、従来の作物画像の解析手法とは異なり、開発手法で



(a) トマト株 A



(b) トマト株 B



(c) トマト株 C

図 2.13 実節間距離と推定節間距離の関係。横軸は日時、縦軸は節間距離を表す。実線は推定節間距離、破線は実節間距離を表し、凡例の $(n - m)$ は第 n 節と第 m 節の節間距離を意味する。

は、複数トマト株の生育段階が異なる時系列の樹体画像を解析する場合においても、閾値調整の必要がなかった。一方で、主茎検出による誤判別削除では、主茎からの距離の閾値処理によって節候補点を削除するか否かを決定する。今回解析に用いた全ての画像は、カメラから被写体までの距離が一定となるようにして撮影したため、全てのトマト株の画像に対して同じ閾値を用いることができた。しかし、カメラから被写体までの距離が様々である場合には、閾値を一意に決めることはできない。今後の研究では、このような場合を想定し、デプスセンサやステレオビジョンなどを用いて被写体の大きさを推定することで [112]、閾値を自動決定する方法を検討している。

開発した節検出手法では、最初に、DTSM によって画素単位での画像分割を行うことで茎領域である画素を抽出し、以降の解析に用いる。そのため、画素単位での画像分割において実際には茎領域である画素が他の領域として誤判別されてしまった場合、その付近の節を検出することはできない。つまり、開発手法の精度は、DTSM の精度に大きく依存するということである。Guo et al. [53] は、実圃場で撮影したムギの画像に対して DTSM を適用することで、植物領域を構成する画素のうち、約 8 割を正確に検出できたと報告しているものの、本研究では DTSM による画像分割精度を定量的に評価しておらず、この点についてはさらなる検証が必要であると考えている。また、画素単位での画像分割を行わずに任意の大きさの窓で画像全体を走査して、Bag of Features によって節領域かどうかを判定していく方法も代替案としてあげられる。しかしこの場合、計算コストが飛躍的に大きくなることに加え、本研究で局所特徴量の計算に用いた SIFT では画素の色情報を用いないため、節とそれ以外の領域の判別が難しくなり、結果として節領域以外での誤検出が多くなることも予想される。一方で、SIFT の改良版として、色情報を考慮した Color-SIFT [12, 48, 152] も提案されており、こうした手法を導入することで、画素単位での画像分割を行わなくとも高い節検出精度が得られる可能性もある。

開発手法では、主茎のおおまかな位置を推定するために主茎を直線で近似した。今回解析に用いたトマト株の主茎は全て直線上に伸びていたため、主茎直線によっておよそその主茎の位置を推定することができていたものの、トマトでは栽培条件によって主茎が曲線上になることがある。この場合、得られる主茎直線はその曲線を直線近似したものになるが、その結果、節は主茎直線から遠い位置に存在することになり、実際に節領域に対応する検出点が誤検出として削除されてしまう可能性がある。この問題を解決するため、今後の研究では主茎を曲線によって近似する方法を考えている。あるいは、主茎直線の当てはまりが悪いほど主茎直線と節の間の距離が大きくなることから、線形回帰の当てはまりの程度から距離の閾値を調整する方法も有効であると考えられる。

開発手法による節検出結果の一例を図 2.14 に示す。一番下の検出領域にあるのは本葉の節ではな



図 2.14 節検出結果の一例。○で囲った領域が開発手法によって検出された節領域。

く、子葉の節であるが、誤って検出されてしまっている。今回解析に用いた画像では、このような子葉節の誤検出がいくつか見られた。また、子葉の誤検出を原因として、節間距離の推定誤差が大きくなる事例も確認された。このような問題の解決方法として、今回は子葉節の領域を負例として Bag of Features の学習に用いたが、今後はあえてそれらを本葉節と同じ正例として用い、本葉節と子葉節の両方を検出対象とすることを考えている。最終的に本葉の節間距離を推定するためには、子葉と本葉の節を判別する必要があるが、これについては検出領域の y 座標によって判別できると考えられる。

Bag of Features に関する研究は現在でも精力的に行われており、これまでも多くの改良手法が提案されている [74, 134–136, 139, 204]。Chatfield et al. [22] によれば、とりわけ Perronnin et al. [134–136] によって開発された Fisher vector と呼ばれる手法で良い結果が得られている。また、本研究では Affinity Propagation を検出節の節位推定に用いたが、これを Bag of Features のコードブック生成に用いた例もある [103, 173]。一方で、近年、Bag of Features に代わる一般物体認識手法として Deep Learning [62] が注目されている。Deep Learning はニューラルネットワークを多層に重ねたものであるが、その計算過程で画像特徴量が自動で計算されるという特徴を有しており、一般物体認識の世界において Bag of Features よりも良い結果を示した例もある [86]。今後の研究では、こうした最新手法の導入による節検出の精度向上も期待できる。

トマトでは、成長するにつれて葉量が増え、単一視点から樹体を見たときに本葉の節が葉に隠れる

場合が多くなる。したがって、開発手法を適用できるのは栽培を始めてからある程度の期間に限られる。一方で、開発手法では最初の処理に DTSM を用いた画素単位の画像分割を行っており、茎だけでなく葉の領域についても高精度で抽出可能であることが確認されている。DTSM の結果から得られる葉画素数は、節のオクルージョン頻度の推定に役立つことが考えられる。そのため、今後の研究では、葉画素数を入力データとして未検出節の発生確率を予測することで、節検出の精度を期待できる期間の画像を自動で抽出する技術の開発を考えている。

第 n 節と第 $(n + 1)$ 節の節間距離における推定誤差は、各節における節検出結果の Recall 値に依存していないことがわかる。これは、節位推定において線形回帰を用いたことに起因すると考えられる。つまり、開発手法では節検出の段階で第 n 節が必ずしも全ての時間で検出されている必要はなく、ある程度の頻度で正確に検出できていれば、線形回帰によって検出できなかった時間における節位置を推定できるということである。反対に、第 n 節の節検出時の Recall 値が高い場合でも、誤検出点が第 n に割り当てられてしまうことで誤った節直線が推定され、第 n 節と隣り合う節の間の推定節間距離の誤差が大きくなる可能性も考えられる。これらのことを考慮すると、節間距離推定の精度を上げるためには、節検出の段階において検出できた節の割合を示す Recall 値よりも検出精度を表す Precision 値を大きくすることが重要であると言える。つまり、誤検出削除の段階で確度の高い領域だけを節領域として残し、それ以外を背景領域として分類することが望ましい。Chen et al. [24] によって提案されている Weighted Random Forest や Balanced Random Forest は分類クラスのサンプル数に偏りのあるデータ（不均衡データ）の分類のために開発された分類器であるが、これらを用いることで分類クラスに重み付けをすることができる。これにより確度の高い節領域だけを抽出することが可能となり、節間距離推定の精度向上が期待できる。

今回は解析に用いた個体数が非常に少なく、開発手法の汎用性を確認するためには不十分であった。また、トマトの節間距離は環境ストレスなどによって激しく影響を受け、低夜温や水分不足などの原因によって隣り合う節が非常に近くなることもある。この場合でも Affinity Propagation による節位推定が適用できるかどうかを検証することは、開発手法の汎用性を証明するうえで特に重要になると考えられる。

本研究では、外光による影響が小さい時間帯に撮影された画像のみを解析に用いた。一般に、トマトの茎は明期と比較して、細胞の長さの変化が活発化する暗期により伸長すると言われており [9, 210, 218]、日中に撮影された画像を解析する必要性は低いように思われる。ただし、明期気温 (DT) と暗期気温 (NT) の差である DIF が明期の茎伸長に影響を及ぼすという報告もあり [157, 218]、開発手法が日中に撮影された画像にも対応する必要は少なからず存在する。

トマトを含めた果菜類では、土壌伝染性病害の回避や低温・高温耐性の付与、果実の商品性向上などを目的とした接ぎ木苗の利用が普及している [205, 207, 218]。一般に、接ぎ木苗は胚軸長や節間距離などの形態が均一なものが好ましいとされており、環境制御によって胚軸長や節間距離を制御することに取り組んだ研究事例もある [218]。こうした研究においてもやはり節間距離の計測は人力で行われており、開発手法の導入による計測の自動化、高速化が期待できる。また、園芸分野においても開発手法の利用価値は高いと考えられる。切り花の重要な品質指標とされる切花長は節数、節間距離および花首長によって決定されるが、このうち節間距離と花首長は管理によって大きく変化することから、切花長を決める大きな要因とされている [235]。一般に、節間距離と花首長は短い方が良いとされており、これまでもそれらを制御するための環境条件などの研究がなされている [223, 235]。一般的に、果菜類と比べて切り花では葉数が少ないことから、葉による節領域のオクルージョンが発生しにくい。そのため、開発手法では果菜類と比べて切り花でより高精度な節検出が可能であると期待される。

本研究では、定点カメラで撮影した時系列のトマト樹体画像を解析に用いた。しかしこの場合、1台のカメラで撮影できる個体数が極めて少なく、得られる作物情報は不十分である。一方で、日本国内の植物工場では、栽培施設内を図 2.15 に示すような自走式ロボットが走行するための設備が整えられているところも多い。これを利用して施設内を移動しながらトマト樹体を撮影し、画像解析によって開花を検出することで着果処理を自動化した研究例もある [217]。また、Fukatsu [45] が開発した図 2.16 に示す装置では、屋外圃場を自動移動しながら作物画像を撮影することが可能である。今後は、このようなハードウェアと本研究で開発したソフトウェアを組み合わせることで、圃場の広い範囲で複数個体の作物の表現型を高速で解析することが可能となることが期待される。また、はじめに述べたように、トマトでは環境ストレスの影響が節間距離に顕著に現れることが知られている。開発手法によって圃場の広い範囲でトマトの節間距離が自動推定されることで、圃場内におけるトマトの生育状態のばらつきが把握できる。将来的には、それに基づく肥料施用や環境制御などの意思決定支援への応用なども期待される。



図 2.15 つくば植物工場内を走行可能な自走式ロボット



図 2.16 Fukatsu [45] によって開発された Mobile Robot Field Server。Fukatsu [45] の図を引用。

第3章

着果期以降におけるトマト樹体画像からの自動果実検出

3.1 はじめに

着果数の自動計測は、精密農業の実現において非常に大きな役割を担う。例えば、圃場の広範囲で着果数の自動計測がなされることで、栽培圃場の収量マップが生成される。そして、生成された収量マップに基づく局所最適管理を行うことで、栽培管理や収穫作業にかかる労働コストの削減や、肥料、農薬などの使用量の最適化などが期待できる [141, 142]。また、熟度別の着果数が把握できれば、収穫日ごとの果実収量が予測でき、収穫果実の貯蔵にかかるコスト推定なども可能となる [175]。このように、着果数の自動計測が可能となることで、農家にとって多くの利益が期待できる。

一方で、着果数の自動計測は育種分野においても重要な役割を担う。果菜類において、着果数は最も重要な育種形質の一つとしてあげられるが、従来の育種開発では果菜類の着果数は育種家などの目視観察によって評価されてきた。そのため、多くの時間と労力を要することとなり、育種開発のボトルネックとなっている現状にある。したがって、自動計測技術の開発により着果数計測が高速化されれば、その結果として育種開発の高速化が期待できることになる。

これまでにも果樹、果菜類などで着果数計測に関する研究は広く行われてきた。その多くで画像解析が用いられてきたが、その理由として画像解析では果実の検出が非破壊、非接触で、さらに高速かつ高精度で可能であるということがあげられる。実際これまでに、リンゴ [1, 65, 101, 161, 162, 171, 174, 175, 202]、オレンジ [54, 89, 155, 156]、モモ [90, 165]、ブドウ [35, 41, 123]、マンゴー [131, 132]、トマト [6, 179]、パイナップル [21]、ブルーベリー [96]、ニガウリ [21] などで画像処理を用いた着果数計測に関する技術開発が行われてきた。近年の研究事例では、Wang et al. [175] は画像解析を用いたリンゴ園の果実収量推定を行っている。著者らは赤と緑のリンゴのそれぞれについ

て、画像から果実を検出するためのアルゴリズムを開発しており、赤いリンゴの検出には HSV 色空間で定義される色相値の閾値処理、緑のリンゴの検出には果実表面における反射領域の円形度の閾値処理を行っている。Zhou et al. [202] は RGB 色空間で定義される 3 つの色特徴量に基づくリンゴ果実検出手法を開発した。著者らは R 値、G 値、B 値の差から求められる新たな色特徴量を提案しており、その色特徴量の閾値処理によって果実領域と背景領域を分割している。Kurtulmus et al. [90] は人間の顔認識に用いられる Eigenface（固有顔）と呼ばれる手法を果実検出に応用している。開発手法では、オクルージョン等の検出が難しい条件下にある果実も検出できるうえ、未熟果も高精度で検出可能である。

上述の既往研究において、画像解析を用いた果実検出手法は多く開発されてきた。しかし、それらの手法に共通する問題の一つとして、閾値調整があげられる。既往研究で開発された手法の多くは色や形、あるいは独自に開発された特徴量に対して閾値を設定する必要がある、またその検出精度は設定された閾値に大きく依存する。しかし、作物は生育状態によって様相が大きく変化するため、一意に閾値を決定することは難しい。さらに、もう一つの問題点として、既往研究では幼果を検出対象としていないことがあげられる。一般に、果実は熟度が進むと他の器官にはない鮮やかな色彩を有するようになるため、画像解析による検出が容易となる。そのため、既往研究の多くは熟果を検出対象としており、未熟果を対象としているものは非常に少ない [89, 90, 96, 155]。さらに幼果ともなると、果実自体が非常に小さいことから熟果、未熟果と比べて画像解析による検出難易度は高くなる。とりわけトマトでは、幼果の色彩が葉や茎などの器官と類似していることから、これまでも幼果の自動検出に関する研究は行われてこなかった。しかし、幼果数は中長期的な収量変動の予測に極めて重要であり、精密農業の実現には欠かせない情報であると言える。

近年では、ハイパースペクトル [125, 151, 192] や熱画像 [160, 171]、超音波 [145] など圃場での果実検出に用いられている。一般に、こういった技術は可視画像解析よりも良好な結果を示す場合が多い。その理由として、可視画像では判別が難しい物体同士でも、可視光以外の波長では全く異なる反射率を有する場合が多いことがあげられる。しかしながら、こういった技術を利用するために必要な機器は高価であることが多く、実用性の低いことが難点となる。そのため、低コストで利用可能な可視画像を用いた技術の開発が強く望まれている。

上述の課題を解決するため、本研究では画像解析と機械学習を用いたトマト果実検出手法を開発した。開発手法は 3 段階の画像分割処理によって構成され、それぞれで画像特徴量の機械学習によって生成された分類モデルに基づいた処理が行われる。そのため、撮影条件の異なる複数のトマト樹体画像を解析する場合でも閾値調整の必要がないという利点を有する。また、開発手法では熟果、未熟果

に加えて、幼果についても高精度で検出可能である。本研究では、まず時系列のトマト樹体画像に対して開発手法を適用し、果実検出手法としての有用性について検証した。次に、開発手法をトマト栽培ベッドのパノラマ画像に適用し、栽培圃場の収量マップ生成への利用可能性について検証した。

3.2 果実検出手法

3.2.1 Pixel-based segmentation

開発手法のフローチャートを図 3.1 に示す。開発手法は3段階の処理で構成され、最初に画素単位での分割処理 (Pixel-based segmentation) が実行される。この処理は、2章の2.2.4項で説明した画素単位での画像分割処理と同様である。ただし、今回は分類クラスを果実、茎、葉、背景の4クラスとし、モデル生成および画像分割を行う。

3.2.2 Blob-based segmentation

前段階の Pixel-based segmentation は画素単位の処理であるため、近傍画素にどのような色特徴が存在するかについて考慮しておらず、結果として多くの誤判別が発生する。そこで、開発手法では次の処理として、連結領域単位での分割処理 (Blob-based segmentation) を実行する。

Pixel-based segmentation により、入力画像内の画素は果実、茎、葉、背景のいずれかのクラスに分類される。Blob-based segmentation ではまず、果実クラスに分類された画素の輝度値を1、その他を0に設定した画像を生成する。次に、この画像に対してラベリング処理を施して連結領域を抽出する。抽出したそれぞれの連結領域を囲む最小矩形を設定し、対応する箇所を入力画像から切り抜く。開発手法では、この生成された画像をブロブ (Blob) と呼ぶ。ここで、前述のように Pixel-based segmentation では多くの誤判別が生じるため、生成されたブロブには果実を含まない領域が存在する。Blob-based segmentation は、これらの誤判別領域を削除することを目的として実行される。

以下、Blob-based segmentation の処理方法について説明する。学習過程では、学習用画像から生成されたブロブを手作業で複数果実領域、単一果実領域、非果実領域の3つに分類する (図 3.2)。次に、これらのブロブから色彩、テクスチャ、形状、サイズなどの特徴量を計算する。色彩特徴には、Pixel-based segmentation と同様の15種類の色特徴量のブロブ内の平均値を用いる。テクスチャ特徴の計算には、まず画像をグレースケールに変換し、輝度値ヒストグラムおよびグレイレベル同時生起行列 (Gray Level Co-occurrence Matrix、以下、GLCM) [55] を生成する。次に、予備実験において果実領域と非果実領域を判別するテクスチャ特徴として最も適することが確認された輝度値ヒストグラムのコントラスト、および GLCM の角度別2次モーメント (Angular Second Moment、以

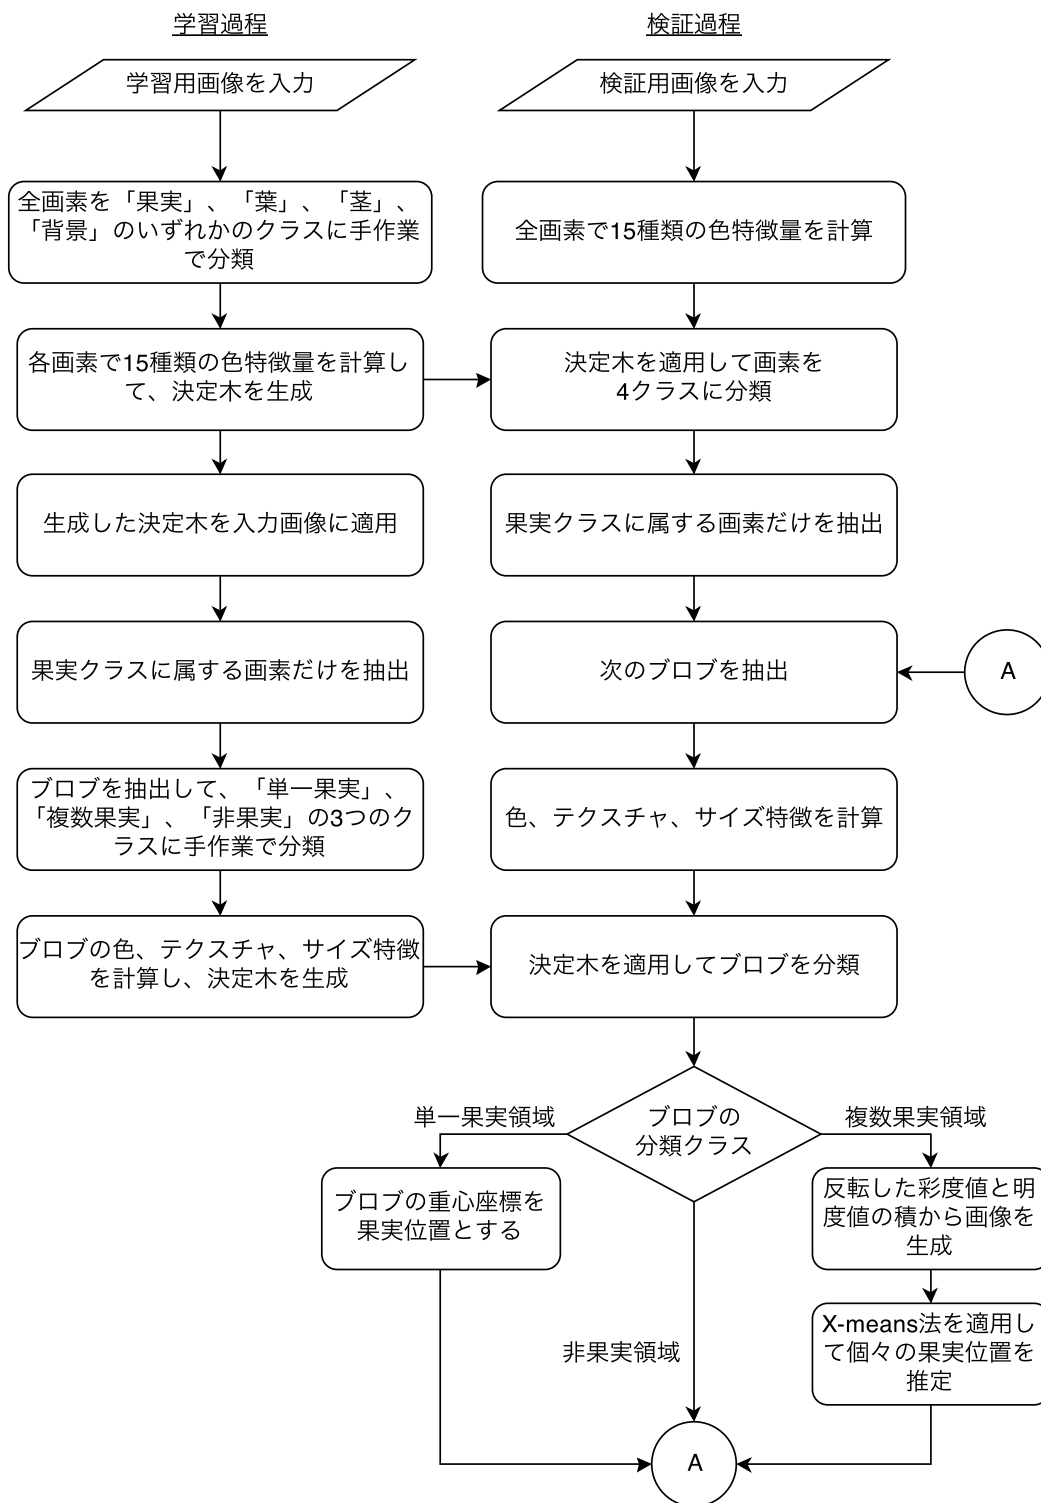


図 3.1 果実検出手法のフローチャート




図 3.2 Blob-based segmentation で用いた学習データの例

下、ASM) を次式により計算し、解析に用いる。

$$\text{Contrast} = \sum_{i,j=0}^{N-1} P_{i,j}(i-j)^2 \quad (3.1)$$

$$\text{ASM} = \sum_{i,j=0}^{N-1} P_{i,j}'^2 \quad (3.2)$$

ここで、 N は画像の階調数、 P は入力画像の輝度ヒストグラム、 P' は輝度ヒストグラムから生成した GLCM を表す。また、 $P_{i,j}$ は輝度値 i と j の出現頻度、 $P_{i,j}'$ は i, j 番目の GLCM の値を表す ($0 \leq i < N, 0 \leq j < N$)。また、形状特徴としてブロブの幅と高さの数値比率（ピクセルアスペクト比）、サイズ特徴としてブロブの総画素数を用いる。最後に、抽出した特徴量とラベル情報を用いて Random Forest [15] に基づく決定木を生成する。

検証過程では、検証用画像から生成されたブロブに対して決定木を適用し、複数果実領域、単一果実領域、非果実領域の 3 つのクラスに分類する。このうち、非果実領域として判定されたブロブを Pixel-based segmentation で生じた誤判別として除去する。

3.2.3 個別果実検出

一般に、トマトは果房を形成するため、Pixel-based segmentation の結果において複数の果実が結合している場合がある。本研究の目的は着果数の計測であるため、複数の果実が結合している場合にはその中に含まれる果実数を推定する必要がある。一方で、Pixel-based segmentation の結果において 1 つの果実が 1 つの連結領域として存在している場合には、その重心座標が果実重心に近い場合が多く、それ以上の処理を行う必要がない。加えて、不要な処理を施すことは精度低下にも繋がる。そのため、開発手法では果実を含む領域を単一果実領域と複数果実領域の 2 種類のクラスに分類した

上で、後者についてのみ以下で説明する個別果実検出処理を施すこととした。

個別果実検出処理の概略図を図 3.3 に示す。図 3.3(a) に示すように、各果実の表面にはカメラのフラッシュに起因する反射領域が認められた。開発手法では、この反射領域を検出することで領域内の果実個数および個別果実位置を推定する。まず、複数果実領域画像の色空間を RGB から HSV に変換する（付録 A 参照）。ここで、果実表面の反射領域では他の領域と比較して彩度（Saturation）値が低く、明度（Value）値が高いことが確認された（図 3.3(b)、図 3.3(c)）。そこで反射領域をより強調するために、彩度値を反転し、明度値との積をとることで図 3.3(d) に示す画像を生成する。

次に、生成した画像に対して x -means 法 [133] による反射領域抽出処理を適用する。 x -means 法は k -means 法 [57] の改良版として開発された手法である。 k -means 法では最終的なクラス数 k をパラメータとして与える必要があるため、今回のようにクラス数（＝減色数）が未知である場合には適さない。一方、 x -means 法ではまず $k = ik$ としてクラスタリングを実行し、次に、生成された ik 個のクラスから新しいクラスを生成するか否か（ $k = 2$ のクラスタリングを実行するかどうか）をベイズ情報量規準（Bayesian Information Criterion, 以下、BIC）と呼ばれる指標を基準として決定する（図 3.4）。この処理を新しいクラスが生成されなくなるまで繰り返すことで、データセットに応じて最適なクラス数が自動で決定される。なお、BIC は以下の式によって定義される。

$$\text{BIC} = -2 \cdot \ln(L) + q \ln(n) \quad (3.3)$$

ただし、 L は尤度関数、 q は独立変数の数、 n はデータの総数を表す。

反射領域を強調した画像の画素値に対して x -means 法によるクラスタリング処理を施すことで、他の領域より極端に大きな値を持つ反射領域はある 1 つのクラスに属するようになる（図 3.3(e)）。開発手法では、 x -means 法の結果から、属する画素の平均輝度値が最も大きいクラスに属する画素を抽出することで果実表面の反射領域を抽出する（図 3.3(f)）。最後に、抽出した画素に対してラベリング処理を施し、得られる各連結領域の重心座標を個別果実位置として用いる。

3.3 解析試料および方法

3.3.1 画像取得

解析に用いたトマト樹体画像は、農業・食品産業技術総合研究機構（NARO）植物工場つくば実証拠点にあるトマト栽培施設内にて撮影した。当該植物工場の概略図を図 3.5 に示す。樹体画像の撮影は、下段左から 4 番目の低段トマト栽培施設にて行った。当該栽培施設の内部の様子を図 3.6 に示す。本研究では、定点カメラを用いて撮影した時系列トマト樹体画像、および空間系列トマト樹体画

像より生成した栽培ベッドパノラマ画像を解析することで開発手法の有用性を検証した。

時系列トマト樹体画像を取得するために、栽培ベッド間に一眼レフカメラ（EOS Kiss X3, Canon Inc., 東京）を設置し、2013年2月7日から同年3月7日までの期間に撮影を行った。栽培施設内における定点カメラの設置位置を図3.7に示す。撮影は夜間に2時間毎に行い、合計154枚の画像を取得した。図3.8に取得した画像の一例を示す。

パノラマ画像の生成には、トマト樹体の中でもっとも未収穫の果実が多かった樹体中段の画像のみを用いた。撮影は手動で行い、隣り合う2枚の画像が重なる部分を持つようにしつつ、施設内の合計2列分の栽培ベッドを撮影した。栽培施設内におけるパノラマ画像の撮影位置を図3.7に示す。栽培ベッドは施設内に合計6列存在し、1列の全長は約13mである。撮影は一眼レフカメラ（EOS 60D, Canon Inc., 東京）を用いて2014年2月6日に行った。また、パノラマ画像の生成には画像処理ソフト（Adobe Photoshop Elements 12, Adobe Systems inc., San Jose）を用いた。生成したパノラマ画像を図3.9に示す。

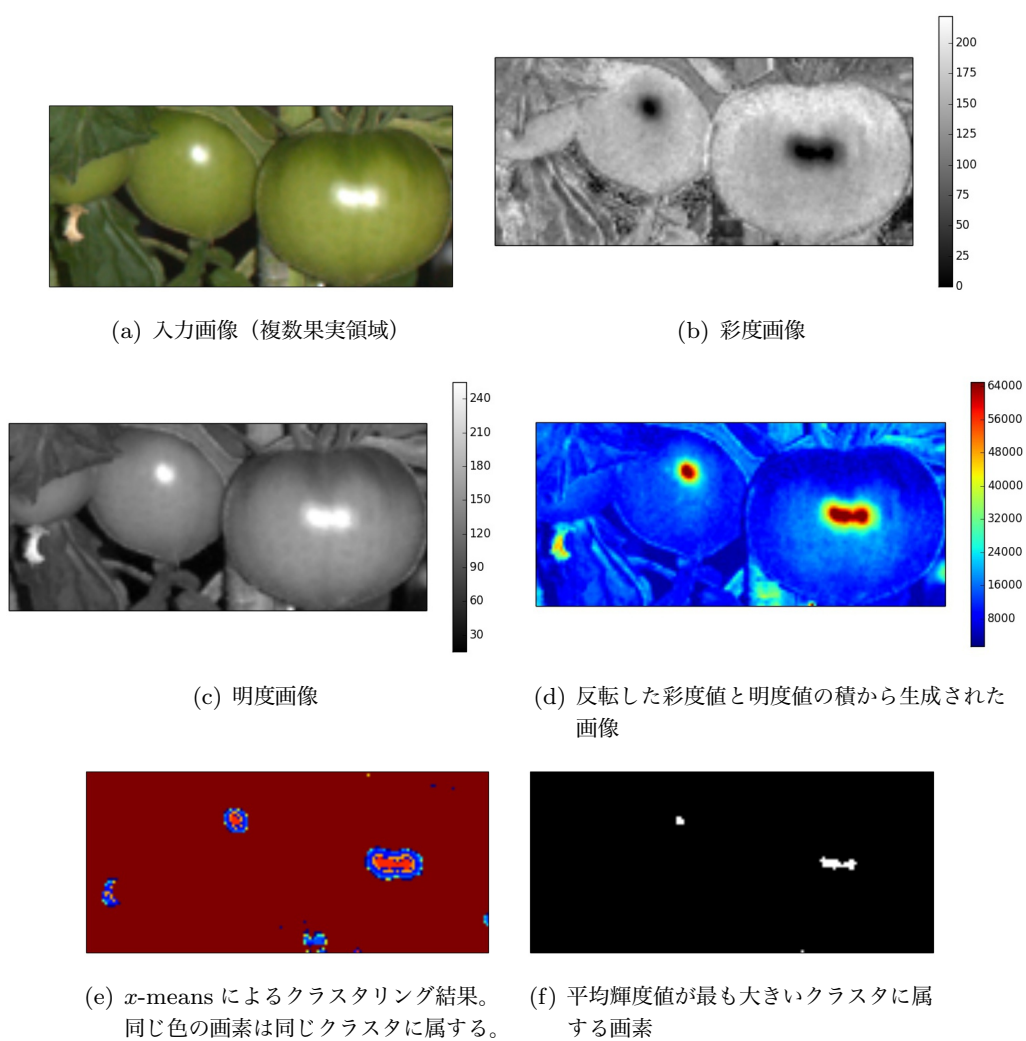
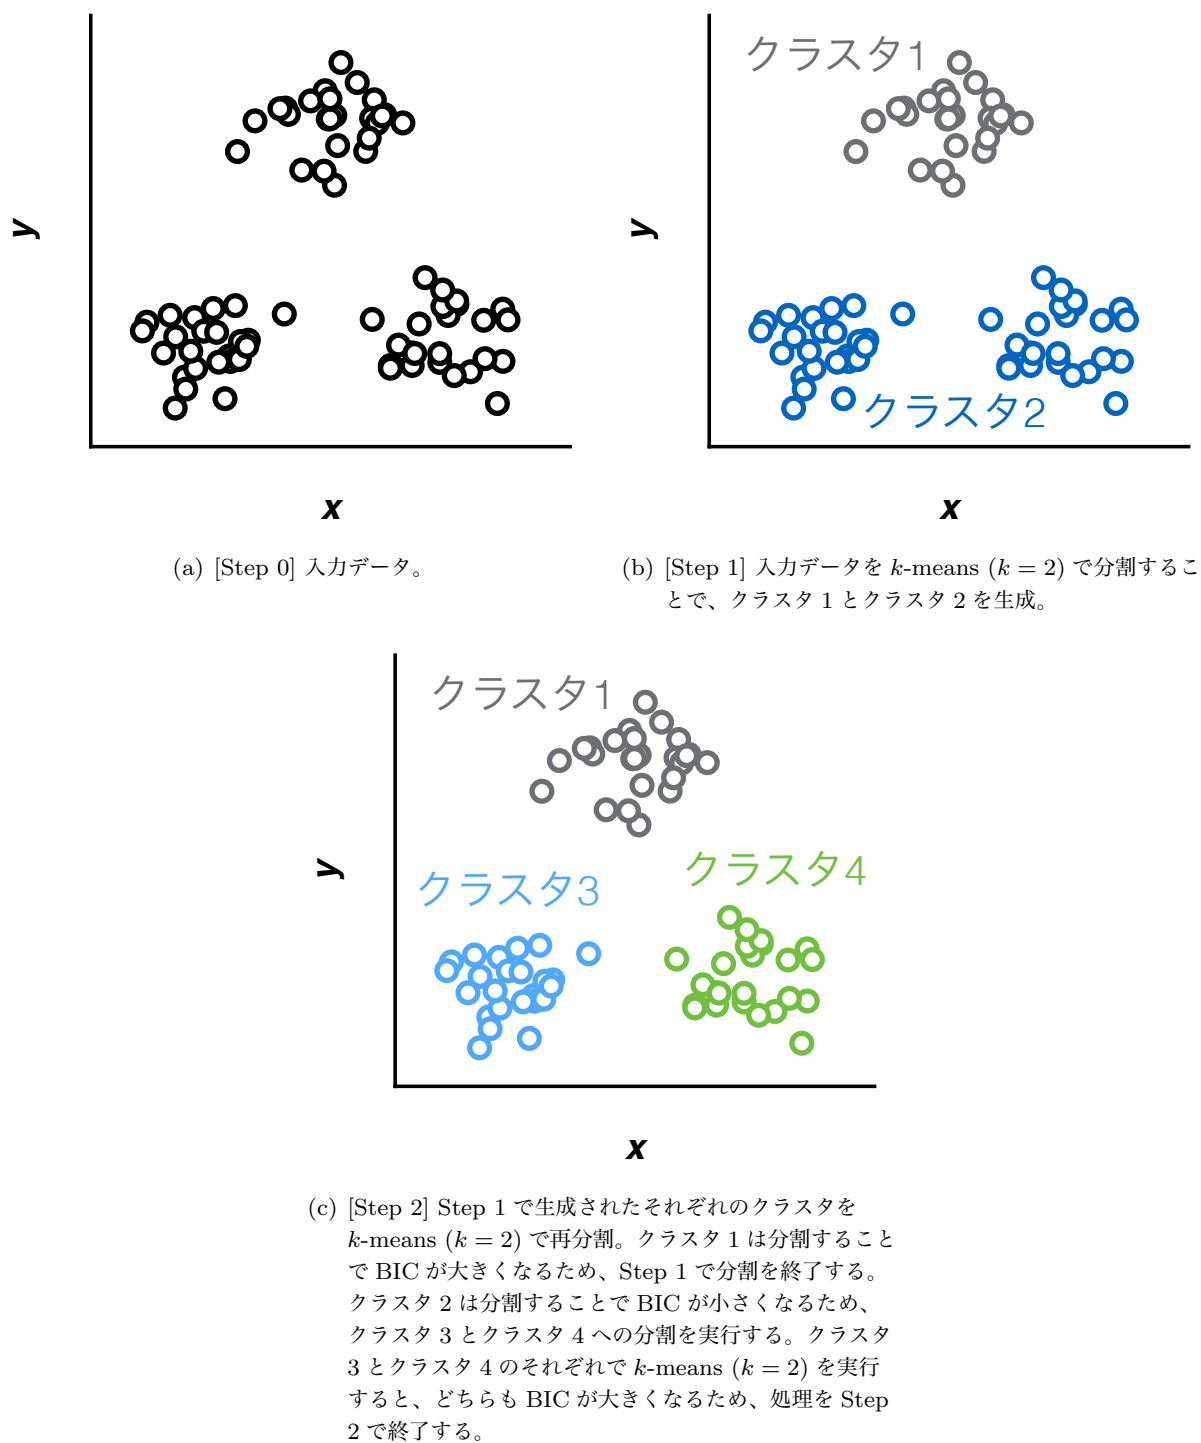


図 3.3 複数の果実を含む領域からの個別果実検出

図 3.4 x -means 法の概略図。同色で示した点が同じクラスタに属することを意味する。

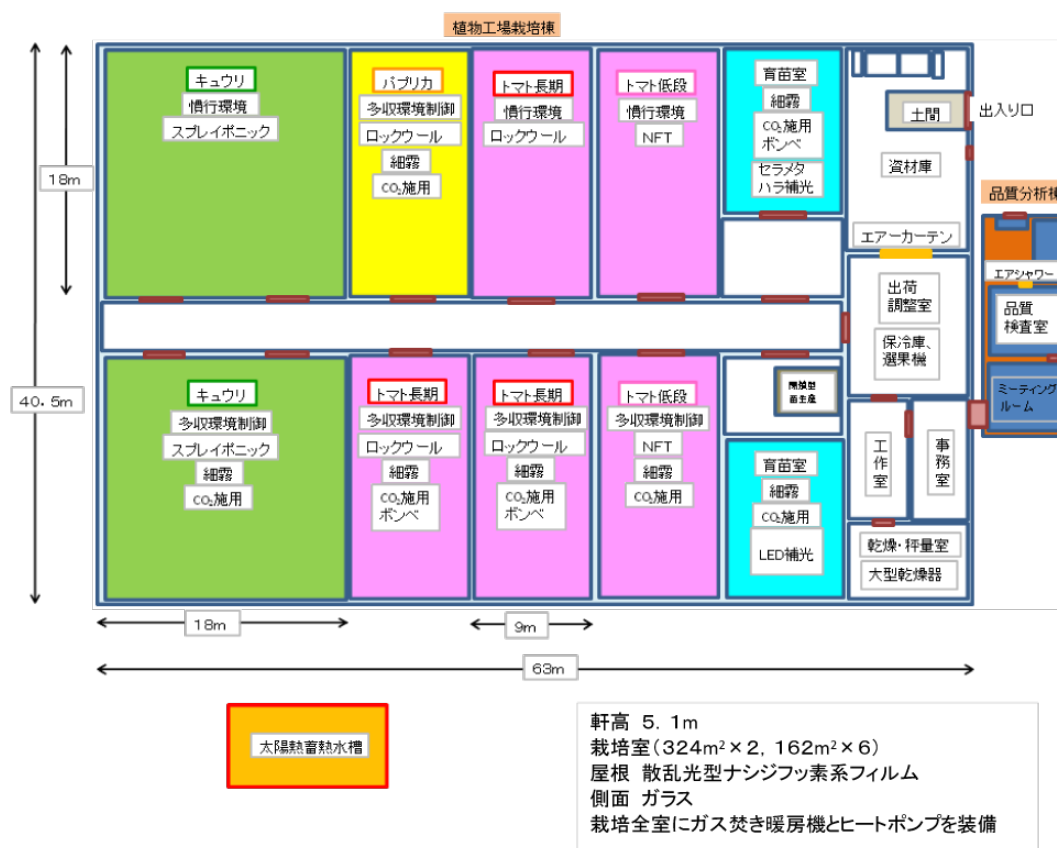


図 3.5 NARO 植物工場つくば実証拠点の施設の概略図。

http://www.naro.affrc.go.jp/vegetea/plant_factory/feature/024217.html から引用。樹体画像の撮影は、下段左から4番目の低段トマト栽培施設にて行った。



(a) 全体



(b) 栽培ベッドの間

図 3.6 トマト栽培施設内の様子




図 3.7 トマト栽培施設内の概略図および樹体画像の撮影位置



(a) 2013 年 2 月 7 日 午後 9 時に
撮影

(b) 2013 年 2 月 28 日 午前 3 時
に撮影

図 3.8 時系列のトマト樹体画像




図 3.9 トマト栽培ベッドのパノラマ画像。全長は約 13m。

3.3.2 機械学習手法のパラメータ決定

機械学習の判別性能は、パラメータの設定値に大きく依存する。開発手法では、Pixel-based segmentation で CART、Blob-based segmentation で Random Forest、個別果実検出処理で x -means 法という3種類の機械学習を用いたため、それらのパラメータの決定方法について述べる。なお、本研究では、全ての機械学習に基づく計算処理に、R version 3.1.0 [143] を用いた。

主要なパラメータとして、CART では剪定を行う木の深さ、Random Forest では作成する決定木の数と各決定木を作成する際に使用する特徴量の数があげられるが、これらのパラメータの調整は2.3.2 項で説明した方法と同様に行った。

x -means 法で重要とされるパラメータとしては、1 回目のクラスタリング処理で生成するクラスタ数、初期クラスタ中心の決定方法の2つがあげられる。このうち、前者については、一般的に用いられる値としてクラスタ数を2とした。また、後者については、ランダムにクラスタ中心を設定する方法を用いた。なお、 x -means 法に基づく計算処理には Ishioka [67] によって開発された R プログラムを用いた。

3.3.3 性能評価

時系列画像の解析には、取得した154枚の中から54枚をランダムに選択し、そのうち13枚を学習用画像、残りを検証用画像として用いた。また、栽培ベッドのパノラマ画像の解析の際は、Leave-one-out 法による交差検定を行った。

開発手法では、Pixel-based segmentation と Blob-based segmentation のそれぞれで学習データが必要となる。時系列画像の解析では、果実クラスで140,000画素、その他のクラスで各100,000画素の学習データを Pixel-based segmentation に用いた。また、Blob-based segmentation では、複数果実領域で30、単一果実領域で200、非果実領域で2,000のプロブを学習データとして用いた。栽培ベッドパノラマ画像の解析には、果実クラスと葉クラスで各50,000画素、その他のクラスで各20,000画素の学習データを Pixel-based segmentation に用いた。また、Blob-based segmentation では、複数果実領域で30、単一果実領域で100、非果実領域で300のプロブを学習データとして用いた。これらの学習データを用いて Pixel-based segmentation と Blob-based segmentation のそれぞれで決定木を生成し、検証用画像に適用した。

Blob-based segmentation では、プロブの分類に Random Forest を用いるため、入力変数の重要度を評価できる。以下、その算出方法について述べる。Random Forest では、決定木を生成する




果実熟度	幼果	未熟果	熟果
例図			
長径 [mm]	30 - 40	41 - 80	41 - 80

図 3.10 本研究における果実熟度の定義

際に、各ノードのジニ係数（Gini coefficient）が小さくなるようにデータを分割していく。分類クラス数を K 、ノード t で i 番目の分類クラスのデータが選ばれる確立を $P(C_i|t)$ とすると、ジニ係数 $GI(t)$ は、以下のように定義される。

$$GI(t) = 1 - \sum_{i=1}^K P^2(C_i|t) \quad (3.4)$$

ノード i に含まれるデータの分類クラスが全て同じである場合、 $GI(t) = 0$ になる。つまり、ジニ係数が大きいほど、分割結果のばらつきが大きいことを表す。本研究では、任意の特徴量によってノードを分割したときのジニ係数の減少量（以下、Mean Decrease Gini）をその特徴量の重要度の指標として用いた。

果実検出の性能評価には、以下に示す 2 つの指標を用いた。

$$\text{Recall} = \frac{\text{画像解析によって検出できた果実数}}{\text{画像中に存在した果実数}} \quad (3.5)$$


$$\text{Precision} = \frac{\text{実際の果実領域に対応する検出領域数}}{\text{検出領域数}} \quad (3.6)$$

Recall は画像中に存在した果実のうち、開発手法によって検出できた果実の割合を表す。また Precision は、開発手法によって検出した全領域のうち、実際に果実に対応する検出領域の割合を表す。

時系列のトマト樹体画像では熟度の異なる複数の果実が存在したため、当該データセットでは果実の熟度別の検出精度も検証した。図 3.10 に、本研究における果実熟度の定義とその例図を示す。なお、栽培ベッドのパノラマ画像には未熟果のみが存在したため、熟度別の精度検証は行わなかった。



(a) 元画像



(b) Pixel-based segmentation により果実クラスと判定された画素



(c) Blob-based segmentation の結果

図 3.11 Blob-based segmentation による誤判別削除の例

3.4 解析結果

3.4.1 Blob-based segmentation による誤判別除去

図 3.11 に、Blob-based segmentation による誤判別除去の一例を示す。図 3.11(b) に示す Pixel-based segmentation の結果画像では、合計 8,715 個のブロブが検出された。ここで、図 3.11(a) に示す元画像には 7 個の果実しか存在していないことから、Pixel-based segmentation で多くの誤判別が発生していることがわかる。しかし、図 3.11(c) に示すように、Blob-based segmentation を適用することでブロブの数は 7 個に絞られ、最終的に 7 個の果実が正確に検出された。以上のことから、Blob-based segmentation によって、Pixel-based segmentation で発生した多くの誤判別を削除できることが確認された。

時系列画像およびパノラマ画像の解析において、Blob-based segmentation で生成した決定木で用いられた各特徴量の重要度を図 3.12 に示す。同図では、横軸の値が、縦軸に列挙された各変数の重

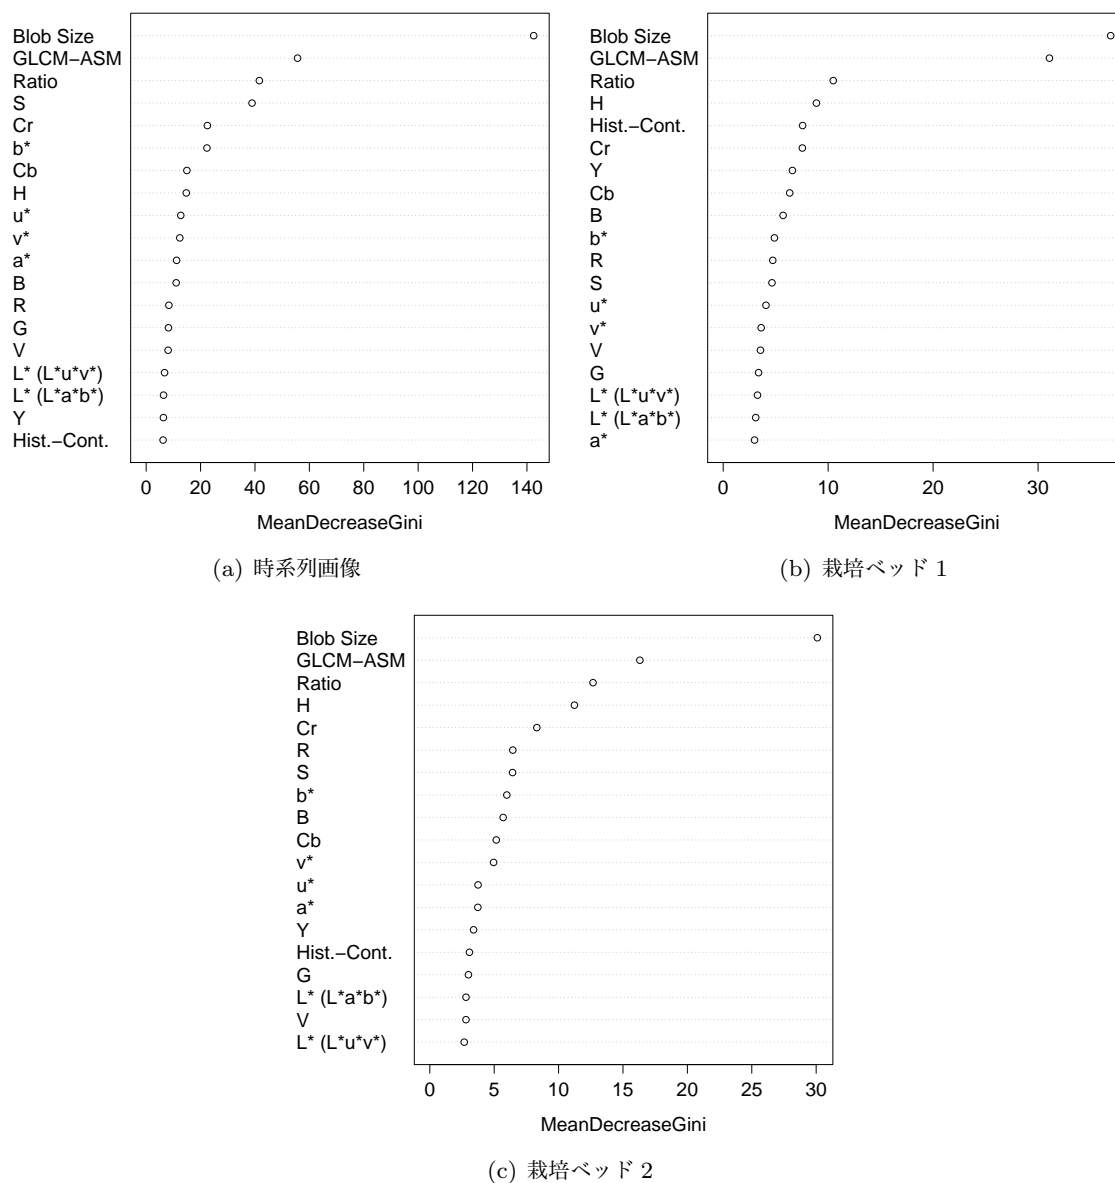


図 3.12 Blob-based segmentation における各特徴量の重要度。横軸の値は各特徴量の重要度を表す。

要度を表している。Blob-based segmentation では、いずれのデータセットにおいてもプロブのサイズがもっとも重要な特徴量であった。また、サイズほどではないものの、GLCM から計算された ASM の重要度も高く評価されている。



図 3.13 画像分割の例

3.4.2 時系列トマト樹体画像からの果実検出

開発手法による時系列画像からの果実検出の結果を表 3.1 に示す。開発手法は検証用画像内に存在した 1,454 個の果実のうち、約 80% を検出することができた ($\text{Recall}=0.80$)。また、開発手法によって検出した領域のうち、88% が実際の果実領域に対応しており ($\text{Precision}=0.88$)、誤検出の発生率が低いことがわかった。果実熟度別では、熟果で 100%、未熟果で 80%、幼果で 78% が検出可能であった。前述のように、トマトの幼果は、他の器官と外観特徴が類似していることに加えて果実自体が非常に小さいことから、画像解析による検出が難しいとされていた。そのため、これまでもトマトの幼果検出に取り組んだ研究事例は存在しなかった。0.78 という Recall 値は十分であるとは言えないものの、初の取り組みとしては良好な結果であり、今後さらなる改善が期待される。

ここで、時系列のトマト樹体画像を図 3.13 に示すように 3 分割し、それぞれで学習データの抽出、分類モデルの生成、および検証用画像からの果実検出を行った結果を表 3.1 に示す。なお、画像を分割する座標は画像内の熟度別の果実分布をもとに任意に決定した。そのため、上段には未熟果と幼果、中段には未熟果のみ、下段には未熟果と熟果が含まれる。画像を分割した場合では、全ての領域において Recall と Precision の値が改善することが確認された。とりわけ幼果における検出精度の向上が顕著であり、Recall 値が 0.07 も改善した。

表 3.1 時系列トマト樹体画像からの果実検出結果

	幼果		未熟果		熟果		全果実	
	Recall	<i>n</i>	Recall	<i>n</i>	Recall	<i>n</i>	Recall	Precision
全段 ^a	0.78	96	0.80	1323	1.00	35	0.80	0.88
上段 ^b	0.85	96	0.84	282	-	-	0.82	0.77
中段 ^b	-	-	0.83	291	-	-	0.82	0.92
下段 ^b	-	-	0.87	750	1.00	35	0.87	0.93

^a 画像全体から得られた学習データを使った結果

^b 画像の一部から得られた学習データを使った結果 (図 3.13 参照)


表 3.2 栽培ベッドパノラマ画像からの果実検出結果

	Recall	Precision	検出した果実数	実際の果実数
栽培ベッド 1	0.82	0.86	110	110
栽培ベッド 2	0.79	0.91	126	126
平均	0.81	0.88	-	-


3.4.3 栽培ベッド内における着果数分布の推定

表 3.2 に栽培ベッドパノラマ画像からの果実検出結果を示す。2つのパノラマ画像の解析結果を平均すると、Recall が 0.81、Precision が 0.88 と、時系列トマト樹体画像の解析結果と同等の良好な結果が得られた。


栽培ベッドのパノラマ画像を横方向に 15 分割した時の、栽培ベッド内における着果数分布を図 3.14 に示す。同図では、横軸がパノラマ画像の x 座標、縦軸が対応する x 座標における果実数を表している。また、図 3.14(a) と図 3.14(c) は開発手法の結果から生成した着果数分布、図 3.14(b) と図 3.14(d) は目視で着果数を数えた結果から生成した実際の着果数分布を表す。なお、パノラマ画像を 15 分割したとき、1 区画あたり約 4 個体が含まれるようになる。また、区画あたりの検出着果数と実際の着果数の相関関係を表 3.3 に示す。パノラマ画像の分割数を 15 とした時、開発手法による検出着果数と実際の着果数の間には強い相関関係が確認された ($r = 0.86^{***}$, $r = 0.92^{**}$)。この結果から、推定された着果数分布は実際の着果数の分布を的確に捉えていたと言える。一方で、分割数を 15 より大きくすると両者の間の相関係数は小さくなることが確認された。




(a) 開発手法で生成した着果数分布 (栽培ベッド 1)



(b) 実際の着果数分布 (栽培ベッド 1)



(c) 開発手法で生成した着果数 (栽培ベッド 2)



(d) 実際の着果数分布 (栽培ベッド 2)

図 3.14 栽培ベッド内での着果数分布 (パノラマ画像の分割数=15)。横軸はパノラマ画像の x 座標、縦軸は対応する座標における果実数を表す。

表 3.3 1 区画あたりの検出果実数と実際の果実数の間の相関関係

	分割数	1 区画あたりの個体数	相関係数	p 値
栽培ベッド 1	15	4	0.86	<0.001
	30	2	0.78	<0.001
	60	1	0.80	<0.001
栽培ベッド 2	15	4	0.92	<0.001
	30	2	0.85	<0.001
	60	1	0.86	<0.001

3.5 考察

本研究では、画像解析と機械学習を組み合わせることで、トマトの樹体画像から果実を高精度で検出できることが確認された。解析には、定点カメラによって撮影した時系列画像と栽培ベッドのパノラマ画像を用いたが、前者の解析結果からは、開発手法によって幼果も含めた果実を高精度で抽出できることが確認された。筆者らが知る限りでは、画像解析によってトマトの幼果検出に取り組んだ事例はこれまでに存在せず、本研究が初の試みであった。また、パノラマ画像の解析結果からは、開発手法によって栽培ベッド内の着果数分布を正確に把握できることが確認された。

時系列のトマト樹体画像に対して開発手法を適用した結果では、検出できた果実の割合を示す Recall が 0.80、検出精度を表す Precision が 0.88 と、良好な結果が得られた。果実熟度別の Recall は、熟果で 1.00、未熟果で 0.80 であり、また最も検出が難しい幼果においても 0.78 と、開発手法によって多くの果実をすることができた。さらに、熟度別の果実分布を元に画像を分割することで、検出結果が大幅に改善されることが確認された。この理由として、樹体を縦方向に分割することで、画像内に含まれる果実熟度や作物の生育状態のばらつきが小さくなり、分類モデルが単純化されたことが考えられる。今後の研究では、画像内の果実熟度などのばらつきをもとに画像を自動分割する技術を開発することで、果実検出精度のさらなる向上が期待できる。

栽培ベッドパノラマ画像の解析結果では、Recall が 0.81、Precision が 0.88 と、時系列トマト樹体画像の解析結果と同等の良好な結果が得られた。一方で、この結果は、開発手法では全体の 19% の果実を検出することができず、また検出した領域の 12% は誤検出であったことを意味する。しかし、それぞれの栽培ベッドにおいて開発手法により検出された総着果数と目視でカウントした総果実は一致していた。この理由として、開発手法では過大評価 (overestimation) と過小評価 (underestimation)

がランダムに発生していることが考えられる。そのため、複数個体の解析結果を総合したことで発生した誤差が打ち消され、結果的に栽培ベッド内の実際の総果実数と検出された総果実数が一致したと考えられる。また、栽培ベッド内の果実数分布の評価において、画像の分割数によって実際の着果数と推定着果数の間の相関係数が上下することが確認された。これも先に述べたように、開発手法ではランダムに過大評価と過小評価が発生するためであり、実際の着果数に近い推定値を得るためには、ある程度の個体数における推定着果数の和を用いる必要があることに関係する。したがって、開発手法を用いた圃場内における着果数分布の把握には、区画あたりの個体数が非常に重要なパラメータとなると考えられた。また、今回対象とした栽培施設はそれほど広いわけではなかったにも関わらず、着果数に大きなばらつきがあることが確認された。このように、開発手法によってトマト栽培施設内における生育状態のばらつきを的確に把握できたことから、今後、精密農業の実現における重要なツールの1つになることが期待される。

本研究では、手動で撮影した複数の画像から栽培ベッドのパノラマ画像を生成した。しかし、撮影にかかる作業コストが大きいため、実際にパノラマ画像を生成できたのは栽培施設全体の3割程度であった。当然のことながら、圃場全体における着果数分布を推定するためにはなるべく広い範囲で画像を撮影する必要があるが、今回のように広い圃場の場合、手動で圃場全体の画像を撮影することは難しい。今回トマト樹体画像を撮影した植物工場では、栽培施設内を自走式ロボットが走行するための設備が整えられており、今後の研究ではこの自走式ロボットにカメラを搭載し、ロボットの走行とカメラの撮影を併せて制御することで栽培施設全体のパノラマ画像を自動で生成することを計画している。

開発手法では、Pixel-based segmentationにおいて、任意の果実の全画素が果実クラス以外に分類されてしまった場合、その果実を検出することはできない。実際に、検証用画像内のいくつかの果実、とりわけ幼果において葉クラスや茎クラスへの誤判別が生じ、結果としてそれらの果実が検出できなかった。こうした問題の解決方法として、例えば時系列の情報を利用することがあげられる。トマトの花は黄色く、他に黄色い器官が存在しないため、果実に比べて画像解析による検出が容易である。また、近い過去の画像において花が存在した領域の近くには、果実が存在する可能性が高いと考えられる。このことから、過去 n 日の間に花が存在した領域については、Pixel-based segmentationの結果に関係なく対応する領域を抽出し、Blob-based segmentationを適用することで、幼果の検出率の向上が期待できる。ただし、こうした処理の必要性を判断するためには、Pixel-based segmentationの精度とその精度が最終的な果実検出に与える影響を定量的に評価することが今後の課題として残されている。

Blob-based segmentation では、すべてのデータセットにおいてプロブのサイズ特徴の重要度がもっとも高く評価された。その理由として、次のことが考えられる。まず、非果実領域のほとんどは画像のノイズに起因しており、数画素で構成されていた。そのため、2種類の果実領域と比較して非果実領域は小さくなり、これらの判別においてプロブのサイズが重要な判別要因となったと考えられる。また、複数果実領域と単一果実領域では、前者が複数の果実を含んでいるため必然的にプロブのサイズが大きくなる。これらの理由から、複数果実領域、単一果実領域および非果実領域の判別において、プロブのサイズ特徴の重要度がもっとも高くなったと考えられた。しかしながら、画像中の物体の大きさという特徴量は、カメラから被写体までの距離に伴って変化してしまう。今回は用いたすべての画像はほぼ一定の距離で撮影されていたため、こういった問題は起こらなかったものの、今後、様々な距離で撮影された画像を解析対象とする場合には何らかの対策が必要となる。対策の一つとして、深度情報を付加することで被写体の大きさを推定する方法があげられる。近年、開発が盛んになっている Kinect (Microsoft, Seattle) や Xtion (ASUS, Taipei) などのコンシューマ向けデプスセンサは、非常に安価であるにも関わらず、高解像度で RGB 画像と深度情報を同時に計測することが可能である。しかし、今回用いた一眼レフカメラと比較すると、未だ得られる画像の解像度は低く、解析に用いるには不十分であると考えられる。一方で、Menesatti et al. [112] は、ステレオビジョンを用いることで物体の実寸と重量を推定できることを確認している。著者らの研究で開発された手法は、一眼レフカメラも利用可能であるうえ、実圃場の環境下でも適用可能であることが証明されており、将来的には本研究の開発手法でも利用することを考えている。

開発手法では、図 3.15 に示すようなオクルージョンなどの条件下においても果実を検出することができた。その理由として、開発手法では画素ベースでの画像分割を行ったうえで、果実領域の判定を行っているということが考えられる。従来の果実検出手法では、画像に検索窓を設置し、画像全体を走査することで果実領域の検出を行うものが多かった。しかし、最適な窓サイズは果実の大きさやオクルージョンの程度によって異なり（図 3.16）、そのため既存手法の重要なパラメータの1つとされていた。本研究の開発手法では、画素ベースでの画像分割において果実と判定された各領域について、それらを包括する最小矩形で画像を切り出し、果実領域であるかどうかの判定を行っている。そのため、果実ごとに最適な窓（プロブ）サイズが自動で決定されており、その結果として図 3.15 のような厳しい条件下にある果実も抽出することができたと考えられる。

本研究では、2次元画像で確認することのできる果実のみを検出対象としていた。しかし、なかには葉や他の果実などによって完全に隠れてしまっている果実も存在しており、検出した果実数と実際の果実数は異なる可能性がある。この問題を解決するため、今後の研究では、回帰分析などによって




図 3.15 難しい条件下における果実検出の例。左が元画像、中央が Pixel-based segmentation の結果、右が決定されたブロブサイズを示す。




図 3.16 異なる条件下における最適な窓サイズの例。黄色の矩形はそれぞれの果実領域における最適な窓サイズを表す。

検出した果実数から実際の果実数を推定することが必要となる。この時、Pixel-based segmentation の結果から得られる葉クラス画素の数を入力データとして用いることで、葉による果実のオクルージョンの発生頻度が推定できると考えられる。また他の方法として、3次元ポイントクラウドの利用もあげられる。樹体の完全な3次元構造が再構築できれば、果実のある側面が他の器官によって隠れている場合でも、視点を変えることでオクルージョンが解消されることがある。実際に、Dey et al. [34] はブドウ畑の3次元ポイントクラウドを生成し、ブドウ果実の検出を行っている。著者らの結果

に関しては、果実検出に3次元ポイントクラウドを導入することの利点について具体的には述べられていないものの、3次元ポイントクラウドから抽出した特徴量を用いることで、高精度で果実領域を検出できることが確認されている。また、近年では、複数視点から撮影した2次元画像群から3次元ポイントクラウドを生成するための技術も多く開発されており[38, 47, 159]、3次元ポイントクラウドを活用した技術開発の気運を高めている。

開発手法は画素ベースでの画像分割 (Pixel-based segmentation)、連結領域ベースでの画像分割 (Blob-based segmentation)、個別果実検出の3段階の処理によって構成される。このうち、最初の2段階では、色、形、サイズ、テクスチャなどの画像特徴量から生成された決定木に基づいて画像分割が行われる。また、個別果実検出では k -means 法の改良版である x -means 法を用いるため、最適なクラスタ数が自動で決定される。そのため、開発手法では作物の状態が異なる複数のトマト樹体画像から果実検出を行う際にも閾値の調整を要さなかった。従来の画像解析手法では、閾値調整にかかる作業コストが普及の大きな障害となっていたことから、これは開発手法の非常に大きな利点としてあげられる。一方で、今日では農業分野においても画像解析と機械学習が併用されることが多く、とりわけ k 近傍法 [2, 101, 123]、サポートベクターマシン [34, 156, 193]、ニューラルネットワーク [6, 90, 171, 193] などの教師あり学習手法が頻繁に用いられているが、この場合、判別精度は学習データの品質に大きく依存する。そのため、良好な結果を得るためには、解析対象に関する情報を網羅する学習データを与える必要がある [53]。本研究の開発手法では、Pixel-based segmentation と Blob-based segmentation のそれぞれで学習データの構築が必要となるが、この作業には多くの時間と労力を要することから、開発手法の普及を妨げる障害となることが予想される。Ruiz-Ruiz et al. [150] や Guo et al. [53] と同様、 k -means 法を用いた半自動の学習データ構築を試してみたものの、異なるカテゴリに属する学習データが同じクラスタに分類されてしまうなど、実用性は低いことが確認されている。しかし、開発手法のユーザビリティを考えると、学習データの構築を効率化するためのツールの開発が必須である。

開発手法では、色彩、形状、サイズ、テクスチャという4種類の画像特徴量を用いた。このうち、色彩に関しては照明条件などによって特徴量が変化することが懸念される。Hashimoto et al. [59] や Menesatti et al. [111] が提案している手法では、自然条件下で撮影した画像の色彩情報から元の色彩情報を復元することが可能であり、開発手法へ導入することで照明条件に対する不変性の確保が期待できる。ただし、著者らの提案した手法では、色彩特徴のリファレンスとしてカラーチャートを撮影対象の近くに配置する必要がある、これが導入の大きな妨げとなる。また、本研究で用いた形状特徴は、画像のアスペクト比という非常にシンプルなものであった。一方で、これまでに多くの高度な形

形状解析手法が提案されており [30, 84, 85, 88]、今後の研究ではこうした手法から得られる形状特徴量の導入も検討している。しかし、本研究で用いた画像では果実の部分的なオクルージョンが多く発生しており、果実の正確な形状特徴を抽出することは非常に難しい。この場合、微細な形状変化を特徴化できる高度な解析手法を適用する方がよいとは必ずしも言えず、この点についてはさらなる検証が必要である。

本研究では、日射による影響が小さい夜間に撮影された画像のみを解析に用いた。開発手法を構成する処理のうち、Pixel-based segmentation に用いた DTSM については、Guo et al. [53] によって日中に屋外で撮影された画像にも適用可能性あることが証明されている。しかしながら、Blob-based segmentation については、外光の変化に対応できるかどうかの検証を行っていない。また、個別果実の抽出処理では、果実表面の反射領域を参考に果実位置を推定しているため、日射が強い日中に撮影された画像に対しては適用できない可能性が高い。一方で、一般に果菜類の果実は夜間に肥大成長することが知られている。また、先に述べたように自走式ロボットなどによって施設を移動しながら撮影する場合には、作業者のいない夜間に実施することが望ましい。以上の理由から、日中に着果量を計測する必要性は低いと考えられ、開発手法を日中に撮影された画像に対応させることは現段階では考えていない。

第4章

画像解析を用いた果実外観特徴の定量的評価

4.1 はじめに

農産物の外観特徴は、食味などと共に商品価値を決める重要な品質要素である [17, 199]。同時に、消費者が特に重視し、価格を決定づける品種の特徴を表わす指標ともなるため、農産物の外観特徴は重要な育種形質の一つともされている。従来、農産物の外観特徴の評価は専門家の目視観察によって行われてきた。しかし、このように人力に頼った評価方法では時間コストが大きいうえに、評価者が作業経験の積み重ねによって獲得した判断要因や判断基準に頼ることが多く、客観性や定量性に欠けることが問題視されてきた [17, 26, 199]。

こうした課題を解決すべく、これまでも農産物の外観特徴の定量評価に関する研究は広く行われてきた。とりわけ品質評価の目的での研究事例が多く、例えば近年の研究例では、López-García et al. [105] がオレンジの自動等級付けシステムを開発している。同システムでは、果実表面の色彩情報に対して主成分分析を適用することで得られる主成分スコアをもとにした独自の指標を提案している。また、その指標に対して閾値処理を施すことで、果実表面に存在する傷の位置と程度を評価している。Pallottino et al. [129] は、画像解析を用いてヘーゼルナッツの皮むきの程度を評価している。著者らの手法では、色情報に k 近傍法という機械学習手法を適用することで、ヘーゼルナッツの画像を種皮、実、背景の3つの領域に自動で分割することを可能としており、結果として従来の閾値処理による画像分割手法よりも高い評価精度を示している。Clement et al. [27] によって提案されたシステムでは、画像解析によってキュウリ果実の長短径や曲率を抽出し、それらを指標としてキュウリの等級付けを行っている。長短径や曲率を算出するためには果実の輪郭を抽出する必要があるが、そのために著者らは、動的輪郭モデルと呼ばれる、エネルギー最小化原理に基づく輪郭抽出手法を用

いている。Lin et al. [99] は、画像解析によって米粒の形状を解析することで、商品価値が極めて低い砕け米の検出を可能としている。著者らの研究では、重心座標から輪郭座標までのユークリッド距離を計算し、得られる数列の導関数によって米粒の輪郭形状を表現している。Yoshioka and Fukino [198] は、画像検索の目的で開発された Content-based Image Retrieval (CBIR) 手法をメロンの色彩評価に応用し、従来手法よりも詳細な色彩評価を可能としている。

また、画像解析から得られた植物の外観特徴量を用いて、遺伝変異や環境変異が外観特徴に与える影響の評価や、外観特徴量に関わる量的形質座位 (Quantitative trait locus、以下、QTL という) を特定した研究事例もある。Yamanaka et al. [190] は、楕円フーリエ法 [88] と呼ばれる形状解析手法を用いてダイズ葉の形状の定量評価を行っている。著者らは新たに作製したダイズゲノムの連鎖地図と楕円フーリエ法によって得られた定量データを併せて解析することで、ダイズ葉の形状に関与する QTL の特定に成功している。また、Iwata et al. [70] も楕円フーリエ法を用いてカンキツの葉の形状を解析している。さらに、抽出した形状データと遺伝子情報、栽培環境情報を併せて解析することで、カンキツ葉の形状のばらつきに対する遺伝子と環境、さらにそれらの相互作用の影響の大きさを評価している。福田ら [233] は画像解析を用いてトルコギキョウの花弁における着色面積率を評価し、品種の覆輪安定性を着色面積率の標準偏差として数量化している。著者らが行った実験の結果では、着色面積率は品種および栽培環境によって有意に変動し、また品種によって栽培条件の影響が異なることを明らかにしている。Okamoto et al. [126] は SmartGrain [163] と呼ばれる画像解析ツールを用いてコムギ穀粒のサイズと形状を解析している。また、抽出した特徴量を用いて QTL 解析を行い、コムギ穀粒のサイズと形状に関わる QTL の特定に成功している。

上述のように、これまでも画像解析を用いた農産物の外観特徴解析は多く行われてきた。しかし、これらの既往研究に共通する問題点として、その多くが色彩や形状などといった1種類の外観特徴に着目しているということがあげられる。一般に、農産物の外観は複数の要素によって複雑に構成されており、1種類の外観特徴を評価した場合に得られる情報は不十分である。例えば、ある果実が理想的な形状を有していたとしても、未熟や劣化などの理由によって色彩やサイズなどに問題があることがある。この場合、その果実の外観品質を適切に評価するためには、形状と併せて色彩、サイズなどの特徴も同時に計測する必要がある。

農作物の外観特徴の定量評価は、育種開発の場面においてもその重要性が高い。農作物では、新品种が開発されると、開発者はその品種の特徴を評価し、品種登録データベース [229] に登録する必要がある。評価項目は多岐にわたり、草姿や節間長、葉長、葉幅、葉の欠刻の有無、果実の色彩や形状、大きさ、子室数などの特徴を登録する必要がある。このうち、節間長や葉長などといった特徴は数値

データとして登録されるが、果実の色彩や形状などの特徴は定性的に分けられた特徴カテゴリから対応するものを評価者の目視評価によって選択し、登録するようになっている。例えば、果実の色彩については「クリーム」、「黄」、「ピンク」、「オレンジ」など、形状については「扁平」、「球形」、「ハート形」、「洋なし形」などの特徴カテゴリが存在する [230]。こうした定性的なカテゴリ分けでは、その中間的な特徴が出てきた場合の分類が難しいことに加え、微細な外観特徴の差異に関する情報が失われてしまう。また、評価者によって評価結果に偏りが発生することも予想される。このような理由から、従来の評価指標を代替する、定量的かつ客観的な外観特徴の評価手法や評価指標の開発が、育種面においても強く望まれている。

本研究では、上述の課題を解決する農産物の外観特徴評価手法の開発に取り組んだ。開発手法では、農作物の複数の外観特徴が定量評価できることに加え、得られた外観特徴量を用いて品種間の外観特徴上の関係性を評価することが可能である。本研究では、従来の定性的な外観特徴指標との比較を通して、得られた外観特徴量の有効性を検証した。また、得られた外観特徴量に基づく品種判別を行うことで、外観特徴量が実際の果実の外観特徴を正確に捉えているかを検証した。最後に、果実間の外観特徴距離を視覚化した結果と実際の果実の外観特徴との比較評価を通して、果実の外観品質評価や育種開発等などの目的における開発手法の利用可能性について考察した。

4.2 解析試料および方法

4.2.1 解析試料

解析試料に用いたトマトは、スーパーマーケット等で購入した。解析に用いたトマトの品種一覧を表 4.1 に示す。解析には、色彩、形状、サイズなどの外観特徴が異なる 8 品種を用いた。また、ぜいたくトマトという品種については、販売時の品質カテゴリが「高品質」と「低品質」で異なる 2 種類の果実を用いた。図 4.1 にそれぞれの品種の果実上面および側面の画像を示す。

4.2.2 画像取得

農産物表面の色彩には、色相や彩度の差異に加え、色彩の空間分布などが存在しており、その構造は非常に複雑である。従って、農産物の色彩解析においてはこの複雑な色彩情報をいかに忠実に撮像するかが重要となる。とりわけトマトなどの光沢を有する農産物では、表面に色飽和が生じ、色彩情報の欠如につながるため、これを除去あるいは軽減することが課題となる。そこで本研究では、Yamamoto et al. [184, 185, 186] と Kimura et al. [79] よって開発された色彩画像撮像装置を用いてトマト果実を撮像した。同装置の外観を図 4.2、概略図を図 4.3、構成部品の一覧を表 4.2 に示す。

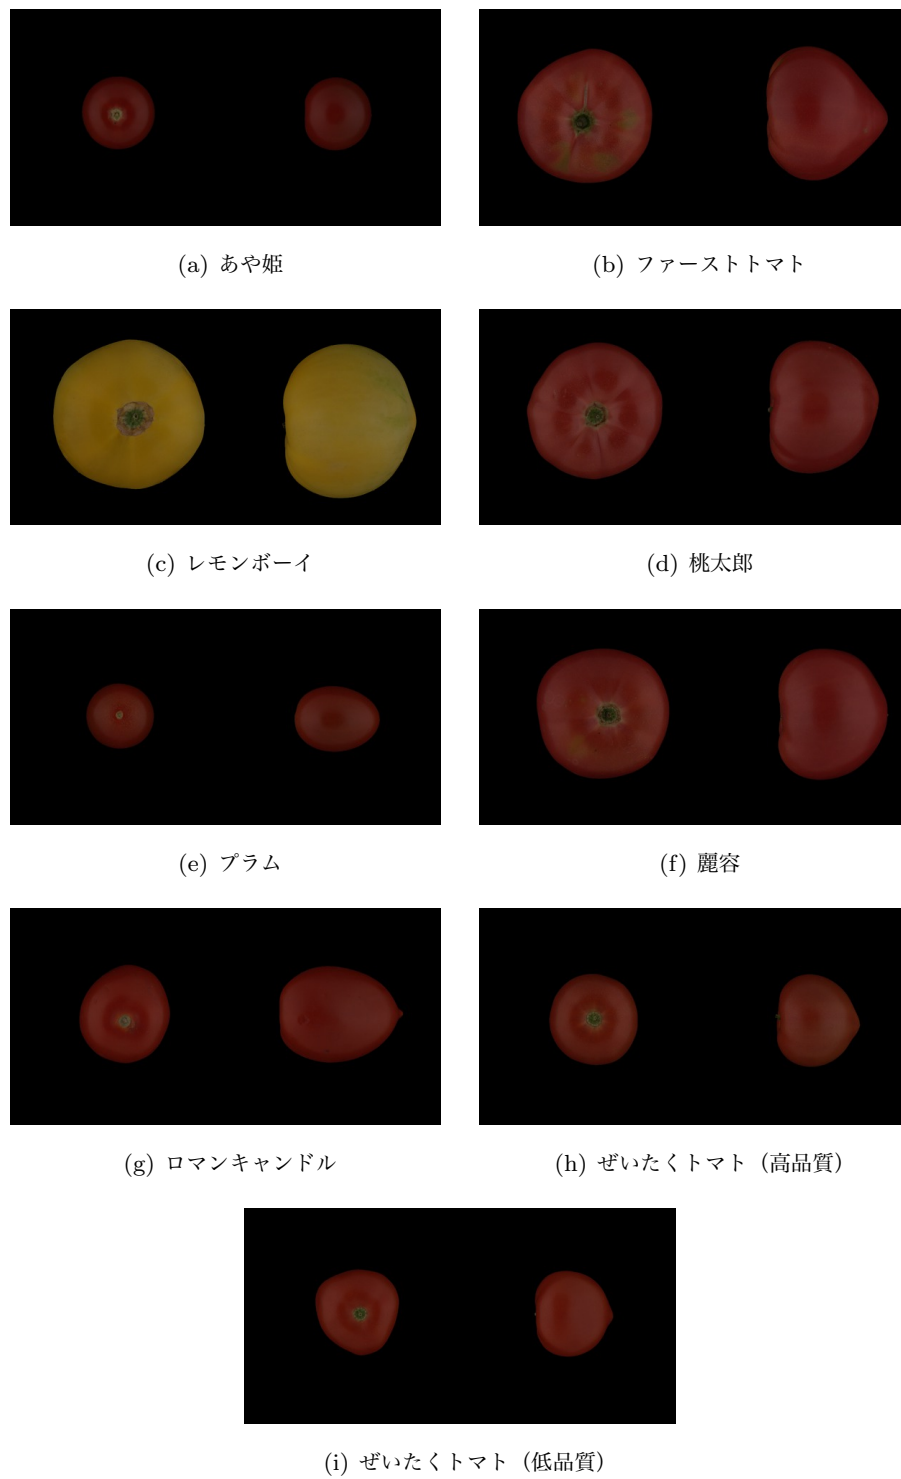


図 4.1 各品種の外観特徴

表 4.1 解析に用いた試料の品種一覧。対応する情報が見つからなかった項目はハイフン (-) で示した。

品種名	果実色彩	平均重量	果実形状	サンプル数	産地	品種 ID
あや姫	濃赤	約 60g	球～腰高	40	宮城	AY
ファーストトマト	桃	約 230g	ハート形	39	愛知	FI
桃太郎	濃桃	約 220g	豊円腰高	46	愛知	MO
プラム	-	30–40g	プラム形状	35	広島	PL
麗容	濃桃	約 240g	豊円腰高	41	熊本	RE
レモンボーイ	黄	200g 弱	Deep globe	17	広島	LE
ロマンキャンドル	-	-	バナナ形	40	愛知	RO
ぜいたくトマト (高品質)	鮮赤	70–120g	-	38	長野	ZH
ぜいたくトマト (低品質)	鮮赤	70–120g	-	35	長野	ZL

表 4.2 色彩画像撮像装置の部品一覧

部品名	製品名
デジタル一眼レフカメラ	D300 (Nikon 社製)
光源	Spiral Vita Lite (TrueLight 社製)
光拡散体	ルミネッセンス・ニュートラルホワイト
モニタ	SyncMasterXL24 (Samsung 社製)

同装置では、光源に補助標準光 D55 に準拠した高い演色性を持つ電球型蛍光灯を用いている。また、光源のスペクトルを維持しつつ拡散光源を作るために、白色度が高く蛍光塗料を含まない紙製の光拡散体を用いている。そのため、物体の色彩情報を正確に記録でき、また物体表面の反射による色彩情報への影響を最小限に抑えられるという特徴を有する。光拡散体の上部にはデジタル一眼レフカメラが設置されており、それらが暗幕で覆われる。光拡散体の上部と下部を蓋して光拡散体内部への外光の侵入を防ぐことで、光拡散体内部の配光が単純化される。また同装置は、様々なサイズの農産物に対応するためのジャッキによる試料高さ調節装置、試料の交換を容易にするための光拡散体開閉装置を備えている。撮影画像のモニタリングは、撮像装置横に設置された色再現性の高いモニタで行う。

外観特徴解析を行うための前処理として、取得した画像に対して背景除去処理を施した。以下、背景除去処理の概要を説明する。取得した画像の色空間を RGB から HSV に変換し、明度チャンネル







図 4.2 色彩画像撮像装置の外観



(a) 正面図




(b) 上面図



(c) 側面図

図 4.3 色彩画像撮像装置の概略図

図 4.4 L*a*b*表色系（<http://www.linocolor.com> から引用）

を抜き出した（付録 A 参照）。画像取得時、背景に黒いフェルトを敷いていたため、果実部分と比較して背景部分では明度値が小さくなることが確認された。そこで、明度値に対して閾値を 30 とした二値化処理を施し、明度値が 30 以上である画素の輝度値を 1、そうでない画素の輝度値を 0 に設定した。次に、この画像に対してラベリング処理を施し、各連結領域における画素数をカウントした。画素数をもっとも多い連結領域領域に対応する画素を果実領域として元画像から抜き出し、以降の解析に用いた。

トマト果実の撮影は購入から 3 日以内に行い、撮影までの期間は冷蔵庫で保管した。ヘタを取り除いて上面、側面、下面を撮影した後、果実重量を計測した。

4.2.3 外観特徴解析手法

色彩解析

果実表面の色彩特徴の指標として、3 次元直交座標によって色を表現する L*a*b*表色系（図 4.4）で定義される 3 種類の色特徴量を用いた。前処理において果実領域として判定された画素のみを対象とし、それらの画素の平均 L*値、平均 a*値、平均 b*値を計算した。色特徴量の計算には、OpenCV 2.4.9 [68] 内の `cvtColor` 関数を用いた。

形状解析

果実形状の解析には、Kuhl and Giardina [88] によって開発された楕円フーリエ法を用いた。また、一連の形状解析には、Iwata and Ukai [69] によって公開されている形状解析アプリケーションの SHAPE ver.1.3 を用いた。以下、楕円フーリエ法の概要について述べる。

楕円フーリエではまず、解析対象の形状から輪郭を抽出し、チェインコード [42] に変換する。この時、輪郭開始画素から p 番目の輪郭画素までの周長 t_p は次のように定義される。

$$t_p = \sum_{i=1}^p \Delta t_i \quad (4.1)$$

ただし、 Δt_i は隣り合う i 番目と $(i-1)$ 番目の輪郭画素の間の距離を意味する。ここで、 p 番目の輪郭画素の x 座標値と y 座標値を次のように定義する。

$$x_p = \sum_{i=1}^p \Delta x_i \quad (4.2)$$

$$y_p = \sum_{i=1}^p \Delta y_i \quad (4.3)$$

ただし、 Δx_i と Δy_i はそれぞれ、 i 番目と $(i-1)$ 番目の輪郭画素の間の x 座標上と y 座標上における距離を指す。ここで、解析対象とする輪郭が閉曲線であれば、式 (4.2) と式 (4.3) から得られる値の集合はそれぞれ周期性を持つようになる。全ての周期関数はフーリエ級数展開によって三角関数の合成関数として表示できることを利用して、 x_p と y_p を以下のように表現する。

$$x_p = A_0 + \sum_{n=1}^{\infty} \left(a_n \cos \frac{2n\pi t_p}{T} + b_n \sin \frac{2n\pi t_p}{T} \right) \quad (4.4)$$

$$y_p = C_0 + \sum_{n=1}^{\infty} \left(c_n \cos \frac{2n\pi t_p}{T} + d_n \sin \frac{2n\pi t_p}{T} \right) \quad (4.5)$$

ここで、 T は解析対象である輪郭の全周長、つまり式 (4.2) と式 (4.3) から得られる値の集合の周期を表す。このとき、それぞれのフーリエ級数は次式から得られる。

$$a_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta x_p}{\Delta t_p} \left(\cos \frac{2n\pi t_p}{T} - \cos \frac{2n\pi t_{p-1}}{T} \right) \quad (4.6)$$

$$b_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta x_p}{\Delta t_p} \left(\sin \frac{2n\pi t_p}{T} - \sin \frac{2n\pi t_{p-1}}{T} \right) \quad (4.7)$$

$$c_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta y_p}{\Delta t_p} \left(\cos \frac{2n\pi t_p}{T} - \cos \frac{2n\pi t_{p-1}}{T} \right) \quad (4.8)$$

$$d_n = \frac{T}{2n^2\pi^2} \sum_{p=1}^K \frac{\Delta y_p}{\Delta t_p} \left(\sin \frac{2n\pi t_p}{T} - \sin \frac{2n\pi t_{p-1}}{T} \right) \quad (4.9)$$

ここで、得られたフーリエ係数はサイズ、回転、移動、起点に対する普遍性を有さないため、以下の式を用いて標準化する。

$$\begin{bmatrix} a_n^{**} & b_n^{**} \\ c_n^{**} & d_n^{**} \end{bmatrix} = \frac{1}{E^*} \begin{bmatrix} a_n & b_n \\ c_n & d_n \end{bmatrix} \begin{bmatrix} \cos n\theta & -\sin n\theta \\ \sin n\theta & \cos n\theta \end{bmatrix} \quad (4.10)$$

ただし、

$$E^* = \sqrt{(A_0 - x_q)^2 + (C_0 - y_q)^2} \quad (4.11)$$

$$\psi = \arctan \left[\frac{y_q - C_0}{x_q - A_0} \right] \quad (0 \leq \psi < 2\pi) \quad (4.12)$$

$$\theta = \frac{2\pi t_q}{T} \quad (0 \leq \theta < 2\pi) \quad (4.13)$$

E^* は輪郭の重心 (A_0, C_0) から輪郭上の最も遠い点 (x_q, y_q) までの距離を表し、 ψ は重心から (x_q, y_q) に向けたベクトルと x 軸がなす角度を表す。また、 θ はチェーンコードの生成過程における起点画素を決定する変数である。

ここで、図 4.1 に示したように、トマトでは品種によって形状のばらつきが大きく、縦長のものや横長のものがある。そのため、先に述べた方法ではサイズ、回転、起点に対する不変性が得られない。そこで、本研究では、形状解析アプリケーションを用いて果底部が (x_q, y_q) となるように手動で設定し、トマト果実の形状を解析した。

サイズ解析

農作物の画像解析で頻繁に用いられるサイズ指標として、周囲長や長径・短径、投影面積などがあげられる [199]。一方で、トマトの場合、図 4.1 に示したように形状のばらつきが大きく、長径や短径が同じであっても、実際の果実の大きさが異なる場合がある。また、トマトでは上面と側面のそれぞれで形状のばらつきが大きいため、正確に果実の大きさを評価するためには、その両方から特徴量を抽出する必要があると考えられる。そこで本研究では、果実サイズの指標として果実上面と側面の投影面積の合計値を用いた。

4.2.4 外観特徴データに基づく外観特徴距離の定量評価

色彩特徴と形状特徴については、それぞれ果実ごとに多次元のデータが得られるため、主成分分析による情報縮約を行った。また、各主成分の外観特徴変異に対する意味を視覚化するために、主成分を定義する固有ベクトルからそれぞれの主成分スコアが 0 または標準偏差の $\pm n$ 倍の値をとり、他の

表 4.3 果実表面における色彩特徴の主成分分析結果

	PC1	PC2	PC3
Eigenvalue	2.56	0.26	0.19
Proportion of variance	0.85	0.09	0.06
Cumulative proportion	0.85	0.94	1.00

主成分スコアがすべて 0 となる時の L*値、a*値、b*値とフーリエ係数を算出し、色彩特徴については RGB 色空間に再変換、形状特徴については逆フーリエ変換による輪郭の再構築を行った。また、サイズ特徴については、実際の果実重量との比較を行い、得られた特徴量の利用可能性について検討した。さらに、得られた外観特徴量を用いた品種間の多重比較検定および品種判別を行い、得られた特徴量が外観特徴の品種間変異を十分に捉えているかを検証した。なお、多重比較検定には Tukey's HSD 法、品種判別には Random Forest を用いた。品種判別における各特徴量の重要度の評価は、3.3.3 項と同様に行った。また、品種判別の精度検証には、次式から得られる指標を用いた。


$$\text{品種判別精度} = \frac{\text{正確に分類された任意の品種の果実数}}{\text{任意の品種の総果実数}} \quad (4.14)$$

以下、主成分分析によって得られる果実色彩と果実形状の主成分スコアおよび果実サイズを用いた外観特徴距離の評価方法について説明する。色彩特徴と形状特徴については、主成分スコアのユークリッド距離を果実間の色彩距離および形状距離として用いた。またサイズ特徴については、得られた果実サイズ指標のユークリッド距離を果実間のサイズ距離として用いた。得られた 3 種類の果実間距離を用いて多次元尺度構成法による二次元平面への射影を行い、得られた外観特徴データの妥当性や育種分野などにおける開発手法の利用可能性について検証した。なお、本章で行うすべての統計解析には、R version 3.1.0 [143] を用いた。


4.3 解析結果

4.3.1 外観特徴の定量評価


果実表面における色彩特徴の主成分分析の結果を表 4.3 に示す。また、各主成分が表す色彩変化を視覚化した結果を図 4.5 に示す。同図から、第 1 主成分は濃赤色から黄色への変化、第 2 主成分は赤色の明暗、第 3 主成分は濃赤色から桃色への変化を示していることがわかる。また、得られた色彩主成分の中には、今回用いた果実の色彩以外の色彩情報が含まれていない。つまり、開発手法によって今回用いたトマトの果実色評価のための色空間を構築できたと言える。



(a) 第1主成分



(b) 第2主成分



(c) 第3主成分

図4.5 それぞれの色彩主成分が表す色彩変化。主成分を定義する固有ベクトルから $L^*a^*b^*$ 値を導いた。横軸は主成分スコアの標準偏差を表す。


表 4.4 楕円フーリエ記述子の主成分分析結果

	PC1	PC2	PC3	PC4	PC5	PC6
Eigenvalue (10^{-3})	30.20	2.04	0.32	0.22	0.09	0.01
Proportion of variance	0.91	0.06	0.01	0.00	0.00	0.00
Cumulative proportion	0.91	0.98	0.99	0.99	0.99	0.99


表 4.1 からわかるように、今回は用いた品種の色彩特徴は赤、桃、黄の3種類に大別でき、そして同じ色彩カテゴリに属する品種同士でも濃淡などの微妙な差異が存在する。ここで、色彩主成分スコアを用いた Tukey's HSD 法による多重比較検定の結果を図 4.6 に示す。同図では、横軸が品種、縦軸が色彩主成分スコアを表しており、図中に示したアルファベットが異なる品種同士は、Tukey's HSD 法による多重比較検定において、有意水準 5% で有意差が認められたことを意味する。色彩主成分を用いた多重比較検定の結果では、いずれかの主成分において、ファーストトマトと麗容を除く、全ての品種間で有意な差が認められた。

果実形状の楕円フーリエ記述子について主成分分析を行った結果を表 4.4、各主成分が示す形状変化を視覚化した結果を図 4.7 に示す。また、図 4.8 には農林水産省によって定められているトマト果実の形状カテゴリを示す。2つの図を比較すると、今回得られた形状主成分では第1主成分が長円筒形およびプラム形から扁平形、第2主成分がハート形から球形への変化を表していることが確認できる。また、それ以降の主成分においては、第3主成分は果実側面の膨らみ、第4主成分は果頂部と果底部の膨らみ、第5主成分は果底部の尖り具合、第6主成分は果頂部の微細な尖り具合を表している。第1-2主成分に比べて、第3主成分以降が表す形状特徴の変化が微細であることは、後者に比べて前者の寄与率が大いことにも対応している(表 4.4)。ここで、各品種の平均形状主成分スコアを表 4.5、平均形状主成分スコアから輪郭を再構築した結果を図 4.9 に示す。同図と図 4.1 を見比べてみると、各品種の様々な形状特徴が今回得られた形状主成分の組み合わせによって正確に表現できていることがわかる。以上の結果から、得られた形状主成分は各品種の形状特徴を正確に捉えていたと考えられる。


色彩と同様、形状についても品種間で微妙な差異が存在する。形状主成分スコアを用いた Tukey's HSD 法による多重比較検定の結果を図 4.10 に示す。形状主成分を用いた多重比較検定の結果では、いずれかの形状主成分において、麗容とレモンボーイを除く、全ての品種間で有意差が認められた。また、桃太郎と麗容では形状第6主成分でのみ有意差が認められた。図 4.7 からわかるように、形状第6主成分が表す形状変化は非常に小さく、目視では見分けることが難しい。この結果から、楕円



(a) 第1主成分



(b) 第2主成分



(c) 第3主成分

図4.6 色彩主成分スコアの品種内でのばらつき。図中に示したアルファベットが異なる品種同士は、Tukey's HSD 法による多重比較検定において有意差が認められた ($p < 0.05$)。

表 4.5 各品種の平均形状主成分スコア

品種 ID	PC1	PC2	PC3	PC4	PC5	PC6
AY	-0.088	-0.038	0.002	-0.008	0.000	0.005
FI	0.058	0.08	0.019	0.01	0.003	0.002
MO	-0.155	0.008	-0.002	-0.001	0.001	-0.004
PL	0.193	-0.041	-0.005	0.006	0.002	0.005
RE	-0.153	-0.002	-0.001	0.000	-0.005	0.001
LE	-0.087	0.003	0.000	-0.004	-0.005	0.002
RO	0.268	-0.026	0.007	-0.008	-0.008	-0.005
ZH	-0.040	0.001	-0.013	0.000	0.007	-0.001
ZL	0.002	0.013	-0.009	0.003	0.004	-0.003

フーリエ法を用いることで、人間には評価の難しい微細な形状特徴の変化も評価できることが確認された。

画像解析によって得られた果実サイズと実際の果実重量との関係を図 4.11 に示す。両者の間には非常に高い相関関係 ($r = 0.99, p < 0.001$) が見られたことから、画像解析によってトマトの重要な形質である果実重量を、色彩や形状などの形質と同時に計測できる可能性が示された。果実サイズを用いた Tukey's HSD 法による多重比較検定の結果を図 4.12 に示す。おおよその品種間で有意差が認められたものの、ファーストトマトと麗容、あや姫とプラムの間では有意差が認められなかった。これらの品種同士は果実の平均重量が近いことが表 4.1 からわかり、多重比較検定の結果はこれに対応するものであると考えられる。

今回得られた 3 種類の外観特徴量（色彩主成分、形状主成分、サイズ）をそれぞれ独立で品種判別に用いた場合、品種判別の精度はそれぞれ 0.82、0.67、0.63 となった。一方で、すべての特徴量を組み合わせた結果では、品種判別の精度が 0.96 と大幅に向上することが確認された。

4.3.2 外観特徴距離の定量評価

色彩主成分スコアを用いて果実間距離を計算し、多次元尺度構成法を適用した結果を図 4.13 に示す。同図では、横軸の値において赤系および桃系と黄系の品種で大きな距離があることがわかる。ここで、図 4.13 のうち、赤系と桃系のトマトがプロットされている左側の部分を拡大した図を図 4.14 に示す。同図では、左上に濃赤系、中央に桃系、右下に鮮赤系のトマトがプロットされていることが確認できる。また、今回用いた品種のうち、色彩カテゴリが不明であった 2 品種（カゴメプラム、ロ

マンキャンドル) についても、近くにプロットされた品種との関係性を評価することで、色彩カテゴリを推定することも可能である。

形状特徴の第1主成分から第6主成分を用いて果実間距離を計算し、多次元尺度構成法を適用した結果を図4.15に示す。カゴメプラムとロマンキャンドルは異なる形状カテゴリに属するが、見た目の形状特徴は非常に近いことが図4.1からわかる。実際に、図4.15ではこの2品種が非常に近い位置にプロットされており、得られた形状主成分上でもこの2品種が非常に類似した特徴を有することを示している。

図4.16において、横軸は果実サイズを表す。同図においても、本研究で定義した果実サイズが大きくなるほど、果実の面積が大きくなっていることが目視で確認できる。

4.4 考察

本研究では、画像解析によってトマト果実の色彩、形状、サイズという外観特徴を定量的に評価することができた。色彩や形状は感性情報の一つであり、その評価結果は個人の経験や知識に依存する[209, 214]。そのため、全く同じ色彩や形状であっても人によって評価は異なり、時には同じ人であっても評価時の環境や体調などによって異なる評価を下すことがある。一方で、開発手法では画像解析を用いるため、こうした評価のゆらぎが発生しないという利点を有しており、この点において従来の目視評価より優れていると言える。ただし、特に色彩特徴のロバスト性を確保するためには、今回のように一定の光条件下で撮影した画像を解析に用いる必要がある。

本研究で得られたトマト果実の外観特徴量を用いて多重比較検定を行った結果では、色彩主成分、形状主成分、サイズ指標のうち、いずれかの特徴量において、全ての品種間で有意差が認められた。この結果から、得られた外観特徴量が各品種の外観特徴を的確に捉えていたと推察できる。一方で、色彩主成分ではファーストトマトと麗容、形状主成分では麗容とレモンボーイ、サイズ指標ではファーストトマトと麗容、あや姫とプラムの間に有意な差が認められなかった。この結果が、本研究で得られた定量指標の分解能に起因するかどうかを明らかにするためには、今後、専門家による目視評価の結果などと比較検証する必要がある。また、品質の異なる同品種(ぜいたくトマト)では、いずれの特徴量においても有意差が認められなかった。一方で、ぜいたくトマトでは、高品質の果実に比べて低品質の果実の形状第1-2主成分と果実サイズにおけるばらつきが大きいことが図4.10と図4.12からわかる。この結果は、トマト果実の品質を決定する要因が、個々の果実外観ではなく果実外観のばらつきの大きさである可能性を示唆している。

果実の外観特徴量に基づく品種判別では、色彩、形状、サイズの特徴量をそれぞれ独立に用いた場

表 4.6 全特徴量を用いた品種判別における各品種の判別結果

正解品種	各品種に分類された果実数								誤判別率 (%)
	AY	FI	LE	MO	PL	RE	RO	ZHL	
AY	40	0	0	0	0	0	0	0	0
FI	0	37	0	1	0	1	0	0	5
LE	0	0	16	0	0	0	0	0	0
MO	0	2	0	40	0	4	0	0	13
PL	0	0	0	0	35	0	0	0	0
RE	0	1	0	4	0	36	0	0	12
RO	0	0	0	0	0	0	39	1	3
ZHL	0	0	0	0	0	0	0	73	0

合と比べ、それらを組み合わせることで判別結果が大きく改善されることが確認できた。これは、全ての品種間において少なくとも色彩、形状、サイズのいずれかの特徴で有意差があるためであると考えられ、複数の外観特徴を同時に計測できる開発手法の有効性を証明していると言える。また、品種判別の精度が0.96と非常に高くなったことは、本研究で用いた画像解析手法によってトマト果実の外観特徴を十分に抽出できていることを示している。ここで、すべての特徴量を用いた品種判別における、品種別の判別精度を表4.6に示す。とりわけ麗容と桃太郎の間で誤判別が多く生じており、それらの判別精度が低い結果となった。その理由として、麗容と桃太郎では色彩第1-3主成分とサイズにおいて有意差が認められたものの、形状特徴においては第6主成分という非常に微細な変化を表す特徴量でしか有意差が認められなかったことが考えられる。図4.17に、すべての特徴量を用いた品種判別における各特徴量の重要度を示す。形状第6主成分の重要度が低く評価されており、その結果、今回のような誤判別が生じたと考えられる。また、このようにある特徴量では有意差があるにも関わらず、有意差のない特徴量が原因となって誤判別が生じることは、複数の特徴量を評価する開発手法の欠点であると考えられる。

本研究の開発手法によって、トマト果実の外観特徴を構成する要素のうち、果実表面の平均色彩値、果実側面の形状、および果実の大きさの自動定量計測が可能となった。一方で、育種開発において計測される項目は多岐に渡り、表1.1からわかるように果実だけ見ても様々な特徴が計測項目としてあげられている。ただし、果実に関する計測項目の多くは色や形、大きさに関連する特徴であることから、本研究で提案した手法を応用することで自動定量計測が可能となると期待される。しかしながら、それらの特徴は従来、育種と栽培のどちらの場面でも実圃場において非破壊で計測されてきた

ものであり、当然のことながら画像解析によって計測を自動化する場合にも同様に実圃場で非破壊で計測されることが望ましい。加えて、計測の自動化によってもたらされるメリットの1つに時系列上における表現型変化の計測があげられるが、このためにもやはり実圃場における非破壊計測が必須となる。しかしながら、実圃場での計測を可能とするためにはまだいくつかの課題が残されている。まず色彩特徴に関しては、実圃場では照明スペクトルや照度等の光条件が不安定であることから、画像解析によって正確な色彩を計測することは極めて難しい。そこで、カラーチャートや照明スペクトルに基づく色彩補正 [59, 60, 111] が必要となってくる。また、果実の形状特徴を2次元画像によって正確に解析するためには、対象物を撮影する際の視点が極めて重要となるが、実圃場において全ての果実を一定方向から撮影することは困難である。そこで、ステレオビジョンなどを用いて作物の3次元構造が再構築されれば、視点に依存しない形状解析が可能となり、こうした問題を解決できる。また、画像上の大きさという特徴はカメラから被写体までの距離によって変化してしまう。そこで、デプスセンサやステレオビジョンなどを用いて被写体までの距離を計測し、その結果から被写体の大きさを推定する必要がでてくる。こうした課題が解決されれば、本研究で計測対象とした特徴に加えて、栽培や育種の場面で重要とされる様々な外観特徴を実圃場において非破壊で網羅的に計測することが可能になると期待される。

多次元尺度構成法により色彩、形状、サイズの3種類の外観特徴距離を視覚化した結果では、類似した外観特徴を持つ果実が近い位置にプロットされることが確認された。この結果から、本研究の解析手法を用いることで人間の感覚に近い外観特徴データが得られたと判断でき、従来の目視観察による外観特徴の評価法を代替する手法となることが期待できる。これまでも述べたように、従来では農産物の外観特徴は目視評価に依存していたため、今回得られた結果のように外観特徴の微細な変化を表わすことは非常に困難であった。多次元尺度構成法の結果では、それぞれの軸がトマト果実の外観特徴の変化を表していることから、今後、様々な用途において有用なデータとなると考えられる。例えば、大量の収穫果実から目的の外観特徴を有する果実を抽出することがあげられる。多次元尺度構成法の結果では、外観特徴が類似した果実同士ほど近い位置にプロットされるため、理想的な外観特徴を有する果実からの距離を果実品質の指標として用いることができる。従って、例えばその距離に閾値を設定することで目的とする果実を抽出することができる。あるいは、新品種が開発された場合、既存の品種との外観特徴上の関係性を評価することで、新品種の商品価値を推定することも可能であると考えられる。

本研究の成果は、育種分野においてもその利用価値が高いと考えられる。本研究で行った統計解析の結果から、得られた外観特徴量によって果実の微細な外観特徴の差異を定量的に評価できることが

示された。これらの外観特徴量を遺伝情報と結びつけることで、外観特徴に関わる遺伝情報の推定や、遺伝情報からの未知形質の予測（ゲノミックセレクション [19, 72, 106]）に利用できると考えられる。また、トマトについては全ゲノムの解読が2012年になされており [166]、今後、遺伝情報と形質の関係を明らかにする研究が飛躍的に進むことが期待されている。開発手法はトマトなどの農産物の遺伝情報の解析にも寄与するものと考えられ、従来手法よりも効率的かつ定量的なフェノタイプング技術としての応用が期待される。







図4.7 各形状主成分が表す形状変化。主成分を定義する固有ベクトルからフーリエ係数を導き、逆フーリエ変換によって形状を再構成した。右から主成分スコアが -2σ 、平均、 2σ の時の果実形状を表し、左はそれらを重ね合わせた図を示す。



(d) 第4主成分



(e) 第5主成分



(f) 第6主成分

図4.7 各形状主成分が表す形状変化。主成分を定義する固有ベクトルからフーリエ係数を導き、逆フーリエ変換によって形状を再構成した。右から主成分スコアが -2σ 、平均、 2σ の時の果実形状を表し、左はそれらを重ね合わせた図を示す。(cont)

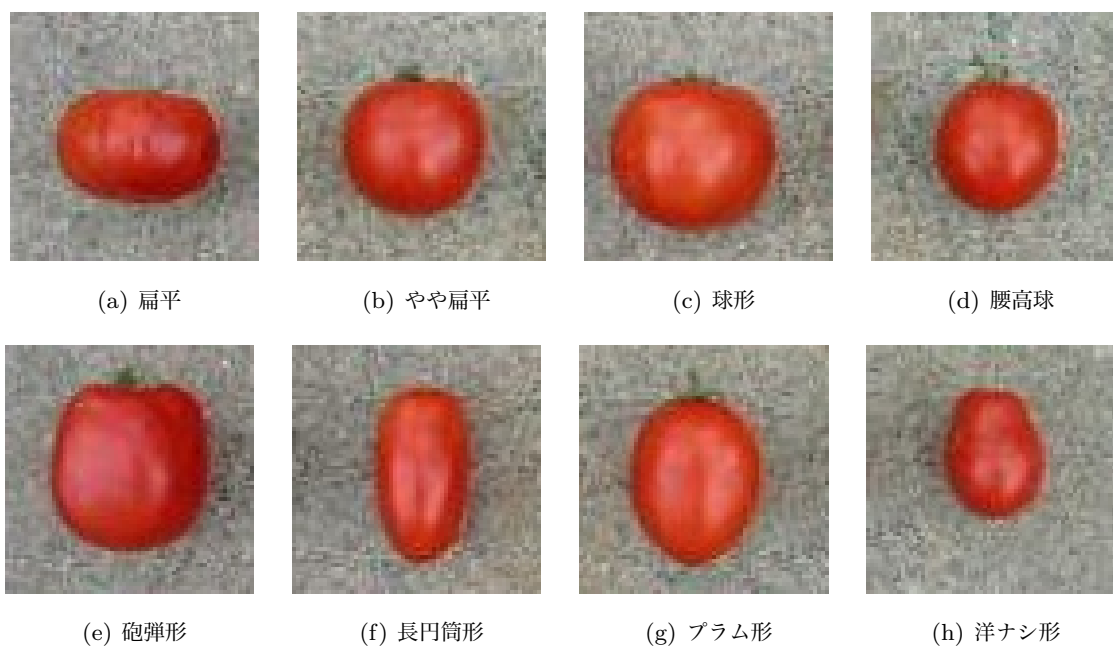


図 4.8 農林水産省によって定められたトマト果実の形状カテゴリ。この他に、「ハート形」という形状カテゴリも存在する。全ての図は農林水産省 [230] から引用した。

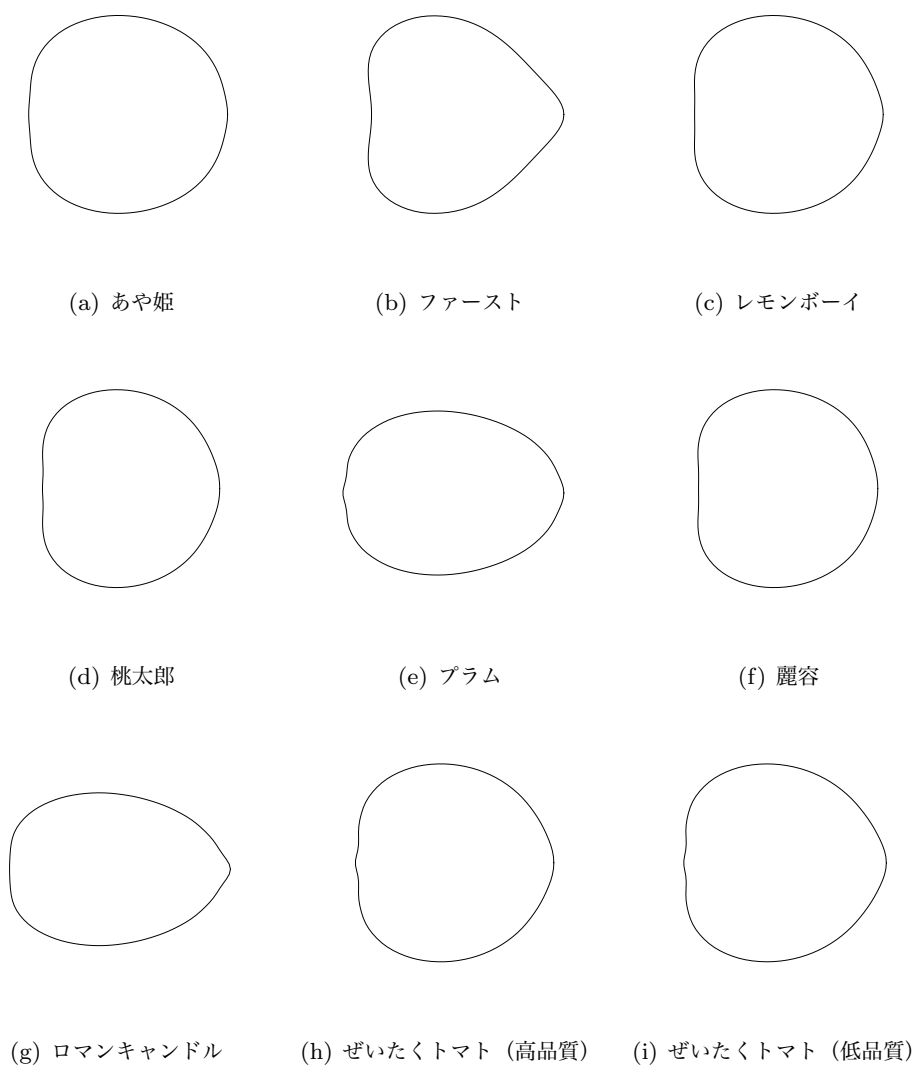





図 4.9 各品種の平均果実形状。各品種の形状主成分スコアの平均値から輪郭を再構築した。



(a) 第1主成分




(b) 第2主成分




(c) 第3主成分


図 4.10 形状主成分スコアの品種内でのばらつき。図中に示したアルファベットが異なる品種同士は、Tukey's HSD 法による多重比較検定において有意差が認められた ($p < 0.05$)。



(d) 第4主成分






(e) 第5主成分




(f) 第6主成分

図 4.10 形状主成分スコアの品種内でのばらつき。図中に示したアルファベットが異なる品種同士は、Tukey's HSD 法による多重比較検定において有意差が認められた ($p < 0.05$)。
(cont)

図 4.11 果実重量と果実サイズの関係 ($r = 0.99, p < 0.001$)図 4.12 果実サイズの品種内でのばらつき。図中に示したアルファベットが異なる品種同士は、Tukey's HSD 法による多重比較検定において有意差が認められた ($p < 0.05$)。




(a) 品種ごとに異なる色、シンボルでプロット




(b) 対応する果実画像でプロット

図 4.13 色彩主成分スコアから得られた果実間距離に多次元尺度構成法を適用した結果。黄色系であるレモンボーイ (LE) のみが離れた位置にプロットされている。




(a) 品種ごとに異なる色、シンボルでプロット




(b) 対応する果実画像でプロット

図 4.14 図 4.13 のうち、赤系と桃系のトマトがプロットされた領域を拡大。濃赤系のあや姫 (AY) が左上、桃系のファーストトマト (FI)、桃太郎 (MO)、麗容 (RE) がその右下、鮮赤系のぜいたくトマト (ZH, ZL) が右下にプロットされている。




(a) 品種ごとに異なる色、シンボルでプロット




(b) 対応する果実画像をプロット

図 4.15 形状主成分スコアから得られた果実間距離に多次元尺度構成法を適用した結果。豊円腰高の桃太郎 (MO) と麗容 (RE) が近い位置にある。また、形状カテゴリは異なるが、近い形状特徴を有するプラム (PL) とロマンキャンドル (RO) も近い位置にある。



(a) 品種ごとに異なる色、シンボルでプロット



(b) 対応する果実画像でプロット

図 4.16 果実サイズの変化の視覚化




図 4.17 すべての特徴量を用いた品種判別における各特徴量の重要度。横軸の値は各特徴量の重要度を表す。

第 5 章

総合考察

5.1 本研究の成果

本研究の成果を、2 章: 生育初期におけるトマト樹体画像からの節検出および節間距離推定、3 章: 着果期以降におけるトマト樹体画像からの自動果実検出、4 章: 画像解析を用いた果実外観特徴の定量的評価 の順に説明する。

2 章では、実際に栽培、育種が行われる環境に近い条件である栽培施設内において撮影された生育初期のトマト樹体画像から、本葉の節間距離を推定するための解析手法を開発した。開発手法は節検出、節位推定、節間距離推定の 3 段階の処理によって構成される。節検出処理では、画像特徴量の機械学習によって画像分割条件を決定するため、異なる個体の生育段階が異なる時系列の樹体画像に適用する場合でも、閾値の調整を要さなかった。また、Bag of Features と呼ばれる一般物体認識手法を適用することで、節検出処理において発生した多くの誤検出が削除され、節検出の結果が大幅に改善されることが確認された。また、検出節の節位推定に Affinity Propagation と呼ばれる非階層クラスタリング手法を採用したため、最終的な節数が異なる個体を解析する場合でもパラメータの調整を要さなかった。さらに、検出節のクラスタリング結果に対して線形回帰を適用することで、未検出節の補間および誤検出による影響の最小化が可能となった。以上の結果を用いることで、節間距離についても高精度で推定可能であることが確認された。

3 章では、栽培施設内で撮影した着果期以降のトマト樹体画像から果実を検出するための解析手法を開発した。2 章と同様、開発手法では、機械学習によって生成された分類モデルを元に画像分割条件を決定するため、作物の状態が異なる複数のトマト樹体画像から果実検出を行う際にも閾値の調整を要さなかった。また、熟果、未熟果に加えて、外観特徴上の問題から可視画像解析による検出が難しいとされてきた幼果についても高精度で検出可能であることが確認された。さらに、開発手法では、最初に画素ベースでの画像分割を行った上でその他の処理を施すため、樹体画像の解析において

深刻な問題となるオクルージョンの問題も解決できることが確認された。トマト栽培ベッドのパノラマ画像画像に対して開発手法を適用した結果では、栽培ベッド内の着果数分布を的確に把握できていたことに加え、開発手法では過大評価と過小評価がランダムに発生することから、栽培ベッド全体における総着果数が正確に推定された。

4章では、収穫後のトマト果実の外観特徴を定量評価するための画像解析技術を開発した。開発技術を用いることで、果実の外観特徴を低次元の特徴量で表現できることに加え、従来の定性的な外観特徴指標を定量値で表すことが可能であった。また、得られた外観特徴量を用いて品種間の多重比較検定を行った結果では、おおよそ全ての品種間で有意な差が認められた。したがって、本研究の外観特徴量は、各品種における外観特徴の微細な差異を的確に捉えていたと考えられた。さらに、得られた特徴量を用いることで、品種間の外観特徴上の関係性を定量的に把握することができた。この結果から、開発手法は特に果実の外観品質評価や育種分野の遺伝子解析などにおける利用価値が高いと考えられた。

以上のことから、本研究では、トマトの様々な栽培ステージにおいて、その生育状態を数量的に把握するための画像解析技術が確立された。開発技術では、全ての処理がコンピュータによって自動的に行われるため、従来の目視による評価方法と比較して、作物の生育状態の評価が高速化されることが期待できる。また、こうした技術は暗黙知である篤農家技術の数値化への利用も期待できる。技術の数値化によって優れた農業技術の継承が促進され、後継者不足による農業技術の消失の問題解決にも貢献すると考えられる。さらには、開発技術によって現在の植物の生育状態を把握し、数値化された判断基準をもとに意思決定支援を行うことで、収量の安定確保や高品質農産物の安定生産にもつながることが期待される。

植物は、生育段階や生育状態によって様相が大きく変化する。そのため、従来の閾値を必要とするような画像解析手法の場合では、作物の状況に応じて閾値を調整する必要があった。2章と3章で開発した手法では、画像分割や領域抽出が機械学習によって生成された分類モデルに基づいて行われる。そのため、汎用性が高いことが期待され、実際に生育段階や生育状態が様々な時系列の樹体画像に対しても適用可能であることが示された。この結果は、開発手法が実際の育種圃場においても利用できる可能性を示唆している。したがって、開発手法によって様々な栽培環境下での高速フェノタイピングが可能となり、育種開発のこれまで以上の効率化が期待される。また、開発手法の他の作物への応用という面でも、開発手法では機械学習を用いていることから、作物ごとに新たな学習データを用意することで可能になると期待される。

5.2 今後の課題

2次元画像解析に共通する問題の1つとして、カメラから被写体までの距離によって被写体の大きさ（投影面積）が変化するということがあげられる。本研究では、この問題に関連する指標として、2章では主茎から節領域までの距離、3章では果実領域を包括する最小矩形の面積、4章では果実表面の投影面積を用いており、そのため、カメラから被写体までの距離が重要なパラメータとなってしまう。この問題の解決策として、今後の研究では、デプスセンサやステレオビジョンなどを用いて被写体までの距離を計測し、その結果から被写体の大きさを推定する方法を検討している。

本研究では、画像解析と機械学習手法を組み合わせることで、作物の表現型を効率的に抽出できることを示した。一方で、開発手法のパフォーマンスは学習データの品質に大きく依存しており、また、機械学習に用いる学習データの選択は、未だ人間の経験や勘に頼るところが多い。そのため、学習データの構築にかかる作業コストが開発手法のボトルネックとなることが予想される。この課題に対する解決策として、(1) 全ての条件を網羅した学習データを用意する、(2) 学習データの構築を支援するツールを開発する、という2つがあげられる。しかし、前者については、複雑な構造を有する作物を解析対象としているため、膨大な学習データが必要となることに加え、特徴の様々な学習データから1つのモデルを構築することは、判別精度の低下にも繋がる。したがって、今後の研究では、開発手法の利便性と性能の両方を確保するために、学習データ構築のための支援ツールの開発を考えている。

画像解析の分野において今、もっとも盛んに研究が行われているのが一般物体認識であり、ここ数年の間にも新しい手法が多く開発されている。その中で、とりわけ注目度が高いのが Deep Learning [62] であり、2012年に開催された ImageNet Large-scale Visual Recognition Challenge では、これまでに一般物体認識の標準的な手法として用いられてきた Bag of Features と比べて格段に良い性能を示している [86]。パラメータ調整の複雑さや計算コストが極めて大きいことなど、様々な問題はあっても、将来的にはこうした手法を導入することで、実圃場における作物画像解析の精度向上も期待できる。

実栽培環境での画像解析には、定点カメラや手動で撮影した画像のみを用いた。しかしこの場合、1台のカメラで撮影できる個体数が極めて少なく、得られる作物情報は不十分である。今後の研究では、自動走行ロボットや UAV などを用いて広範囲で作物画像を自動撮影し、その画像を解析することで複数個体の作物情報を高速に抽出することを考えている。また、開発手法をスマートフォンやタブレットなどの小型デバイスに移植することも考えている。デバイス付属のカメラで撮影した画像、

あるいは動画をリアルタイムで解析できれば、利用者は圃場を歩きながらデバイスで撮影するだけで、広範囲での複数個体の生育診断、表現型解析を行うことが可能となる。さらに、抽出した作物情報と GPS 情報を組み合わせれば、作物の生育状態のばらつきを可視化する圃場マップの生成も可能となることが期待される。こうしたことが実現されて初めて、本当の意味での高速フェノタイピングが可能となる。

本研究で開発した画像解析手法によって、トマトの果実数、節間距離、果実の外観特徴の自動計測が可能となった。一方で、トマトの生育診断や育種開発の場面で評価される形質は数多であり、開発手法ではそれらのごく一部が評価できるようになったに過ぎない。より正確な生育診断や実際の育種現場での利用を考えれば、さらに多くの形質を網羅的に評価するための手法の開発が必須である。ここで、表 1.1 に示したトマトの品種登録時に必要な計測項目を見てみると、多くの項目が画像解析によって計測できそうなことがわかる。とりわけ果実に関しては、果径比のような単純な形状特徴や果実の一部領域における形状特徴、幼果の色彩特徴など、本研究で開発した技術を応用することで計測が可能になるものが多い。また葉に関しても、葉長や葉幅、葉の欠刻の有無、葉の緑色の強さなどは、本研究で用いた色彩解析手法と形状解析手法によって自動計測が可能となるとだろう。しかし、これらの特徴を実圃場で非破壊で計測する場合には、何らかの対処が必要となる。例えば色彩特徴に関しては、照明条件が不安定である実圃場において正確な色彩を計測することは容易ではないため、Hashimoto et al. [59, 60] や Menesatti et al. [111] が提案している手法を用いた色彩補正を行う必要が出てくる。また、果実や葉などの形状特徴を 2 次元画像によって正確に解析するためには、対象物を撮影する際の視点が極めて重要となるが、作物の 3 次元構造が再構築されれば、視点に依存しない形状解析が可能となり、こうした問題を解決できる。大きさに関する特徴を実圃場で計測するには、上でも述べたようにデプスセンサやステレオビジョンなどを用いて被写体までの距離を計測し、その結果から被写体の大きさを推定する方法が有効であると考えられる。その他の計測項目では、心止まり性の強弱は、本研究で開発した節間距離推定手法を応用することで自動計測が可能であると考えられる。また、草姿はトマトの生育診断においても重要な指標の 1 つとされているが、植物の草姿を画像解析によって評価している研究例もすでに存在し [121]、こうした技術を応用することが可能であるだろう。果肩部のひだ、葉の上面の膨らみ、果実表皮の種類といった特徴は、果実表面のテクスチャ特徴を解析することによって定量的な評価が可能である。一方で、現段階では実圃場における計測の自動化が難しそうな項目もいくつかある。例えば、小葉の大きさと着生角度、果柄の離層の有無とその長さなどの特徴は、小葉や果柄が複雑な領域であるためそれら自体を検出することが難しく、画像解析による計測の自動化にはまだまだ多くの課題が残る。また、開花や果実成熟の早晩は、

計測する花および果実が具体的に定義されており^{*1}、それらをどう抽出するかが大きな課題となる。また、画像解析を用いた病害、虫害の発生検出については、トマトに限らず様々な作物で既に多くの研究事例があり [87, 118, 124, 183, 201, 203]、これらの技術を応用することで被害程度の定量的な評価が可能となることが期待される。このようにまだまだ多くの課題が残ってはいるものの、これが解決されれば、実圃場において非破壊で様々な作物の表現型を網羅的に自動計測することが可能となると期待される。

本研究では、トマトの表現型を評価するための画像解析技術をいくつか開発した。将来的には、これらの技術をオープンソースとして公開し、様々な分野で利用できる形にすることを予定している。また、現在は Character User Interface (CUI) でのみ実行可能なプログラムになっているが、取り扱いの簡便さと幅広い分野での普及を考え、将来的には Graphical User Interface (GUI) の実装も予定している。

画像解析を用いた作物の表現型解析に関する研究は、未だ発展途上であり、近い将来に多くの技術が開発されることが期待される [52]。しかしながら、作物の画像解析では、作物画像の取得や真値の設定に多大な労力を要することが研究開発の大きな妨げとなっている。一方で、一般物体認識などの分野においては、すでに多くの画像データベースが存在しており [37, 39, 170, 180]、研究者らは共通の画像を用いて新たに開発したアルゴリズムの性能を検証し、既存手法との比較を行っている。こういった画像データベースが農業分野には未だ存在せず、研究者らは各々用意した画像を使って開発アルゴリズムの性能を検証している。本研究では、トマトについて多くの画像を撮影し、果実位置、節位置、果実外観などに関する真値を有している。今後は、類似研究を行う多くの研究者に向けて本研究で得られたデータセットを公開することで、当該研究分野の発展に寄与したいと考えている。

^{*1} 開花については第2花房と第3花房の第3花、果実成熟については第2果房と第3果房の第3果。

付録 A

表色系

ある色を、心理的特性または心理物理的特性によって定量的に表すための系を表色系と呼ぶ [232]。以下、本研究で用いた 5 つの表色系について、その概要と色特徴量の算出方法を説明する。

A.1 RGB 表色系

RGB 表色系では、光の三原色である赤 (R)、緑 (G)、青 (B) の混合比によって色を表現する。このように色の足しあわせによって色を表現する方法を加法混色と呼ぶ。

光スペクトルから RGB 表色系への直接変換は可能ではあるものの、図 A.1 に示す等色関数が負の値をとることや、用いる RGB 表色系 (CIE RGB, sRGB, Adobe RGB など) によって等色関数が異なることが問題となる。そこで、一般的に光スペクトルから RGB 表色系への変換は、光スペクトルを XYZ 表色系に変換し、XYZ 表色系から RGB 表色系へと変換する方法が用いられる。

ある光スペクトル $S(\lambda)$ から CIE XYZ 表色系への変換は、以下の式によって行われる。

$$X = K \int_{\Lambda} \bar{x}(\lambda) S(\lambda) d\lambda \quad (\text{A.1})$$

$$Y = K \int_{\Lambda} \bar{y}(\lambda) S(\lambda) d\lambda \quad (\text{A.2})$$

$$Z = K \int_{\Lambda} \bar{z}(\lambda) S(\lambda) d\lambda \quad (\text{A.3})$$

ここで、 $\bar{x}(\lambda), \bar{y}(\lambda), \bar{z}(\lambda)$ はそれぞれ図 A.2 に示す X, Y, Z の等色関数、 Λ は等色関数の波長域、 K は比例係数を表す。また CIE XYZ 表色系から CIE RGB 表色系への変換は、以下の式によって行われる。

$$\begin{pmatrix} R \\ G \\ B \end{pmatrix} = \begin{pmatrix} 2.3706743 & -0.9000405 & -0.4706338 \\ -0.5138850 & 1.4253036 & 0.0885814 \\ 0.0052982 & -0.0146949 & 1.0093968 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \end{pmatrix} \quad (\text{A.4})$$




図 A.1 CIE RGB 等色関数




図 A.2 CIE XYZ 等色関数

A.2 HSV 表色系

RGB 色空間を含めた線形色空間には、人間の色の位相に関する直感を捉えていないという問題があるが、HSV 表色系ではこうした問題が解決される。HSV はそれぞれ色相 (Hue)、彩度 (Saturation)、明度 (Value) を意味しており、他の表色系と比べて、色の表現方法がより人間の感覚に近いものであると言える。また、HSV 表色系では色彩情報と明度情報を分離できることから、画像認識の分野において頻繁に用いられる。

RGB 色空間から HSV 色空間への変換は、以下の式によって行われる [127]。

$$V = \max(R, G, B) \quad (\text{A.5})$$

$$S = \begin{cases} \frac{V - \min(R, G, B)}{V} & \text{if } V \neq 0 \\ 0 & \text{otherwise} \end{cases} \quad (\text{A.6})$$

$$H = \begin{cases} \frac{60(G-B)}{S} & \text{if } V = R \\ \frac{120+60(B-R)}{S} & \text{if } V = G \\ \frac{240+60(R-G)}{S} & \text{if } V = B \end{cases} \quad (\text{A.7})$$

8 ビット画像へ変換するには、さらに以下の計算が必要である。

$$V = 255 \times V \quad (\text{A.8})$$

$$S = 255 \times S \quad (\text{A.9})$$

$$H = \frac{H}{2} \quad (\text{A.10})$$

A.3 L*a*b*表色系

CIE L*a*b*は、1976 年に CIE (Comission internationale de l'éclairage) によって定められた表色系である。明度を L*、色度を 2 つのクロマティクネス指数 a*, b*で表し、その色空間は球型になる。L*a*b*色空間は知覚色の均等性を意図して作られた空間 (均等色空間) であるため、2 色間の差である色差を評価するのに優れている。

RGB 色空間から CIE L*a*b*色空間への変換は、以下の式によって行われる [127]。

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{pmatrix} \cdot \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (\text{A.11})$$

$$X = \frac{X}{X_n} \quad \text{ただし、} X_n = 0.950456 \quad (\text{A.12})$$

$$Z = \frac{Z}{Z_n} \quad \text{ただし、} Z_n = 1.088754 \quad (\text{A.13})$$

$$L = \begin{cases} 116 \times Y^{\frac{1}{3}} - 16 & \text{if } Y > 0.008856 \\ 903.3 \times Y & \text{otherwise} \end{cases} \quad (\text{A.14})$$

$$a^* = 500(f(X) - f(Y)) \quad (\text{A.15})$$

$$b^* = 200(f(Y) - f(Z)) \quad (\text{A.16})$$

$$\text{ここで、} \quad (\text{A.17})$$

$$f(t) = \begin{cases} t^{\frac{1}{3}} & \text{if } t > 0.008856 \\ 7.787t + \frac{16}{116} & \text{otherwise} \end{cases} \quad (\text{A.18})$$

$$(\text{A.19})$$

8ビット画像へ変換するには、さらに以下の計算が必要である。

$$L = L \times \frac{255}{100} \quad (\text{A.20})$$

$$a^* = a^* + 128 \quad (\text{A.21})$$

$$b^* = b^* + 128 \quad (\text{A.22})$$

A.4 L*u*v*表色系

L*a*b*表色系に関連する表色系として、L*u*v*表色系が挙げられる。L*a*b*色空間と同様、均等色空間の1つである。L*a*b*表色系とL*u*v*表色系の大きな違いは、クロマティクネス指数の定義にある。

RGB色空間からCIE L*u*v*色空間への変換は、以下の式によって行われる [127]。

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = \begin{pmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{pmatrix} \cdot \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (\text{A.23})$$

$$L = \begin{cases} 116 \times Y^{\frac{1}{3}} & \text{if } Y > 0.008856 \\ 903.3 \times Y & \text{otherwise} \end{cases} \quad (\text{A.24})$$

$$u' = \frac{4 \times X}{X + 15 \times Y + 3Z} \quad (\text{A.25})$$

$$v' = \frac{9 \times Y}{X + 15 \times Y + 3Z} \quad (\text{A.26})$$

$$u* = 13 \times L \times (u' - u_n) \quad \text{ただし、 } u_n = 0.19793943 \quad (\text{A.27})$$

$$v* = 13 \times L \times (v' - v_n) \quad \text{ただし、 } v_n = 0.46831096 \quad (\text{A.28})$$

8 ビット画像へ変換するには、さらに以下の計算が必要である。

$$L = L \times \frac{255}{100} \quad (\text{A.29})$$

$$u* = \frac{255}{354(u* + 134)} \quad (\text{A.30})$$

$$v* = \frac{255}{256(v* + 140)} \quad (\text{A.31})$$

A.5 YCbCr 表色系

YCbCr は、動画や画像の JPEG 圧縮に用いられる表色系である。Y は輝度信号、Cb と Cr は色差信号を表す。

RGB 色空間から YCbCr 色空間への変換は、以下の式によって行われる [127]。

$$Y = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (\text{A.32})$$

$$Cr = (R - Y) \times 0.713 + 128 \quad (\text{A.33})$$

$$Cb = (B - Y) \times 0.564 + 128 \quad (\text{A.34})$$

8 ビット画像へ変換するには、さらに以下の計算が必要である。

$$Cr = Cr + 128 \quad (\text{A.35})$$

$$Cb = Cb + 128 \quad (\text{A.36})$$

付録 B

非階層的クラスタリング手法の比較

本研究では、非階層的クラスタリング手法として検出節の節位推定に Affinity Propagation、複数果実領域における個別果実の位置推定に x -means 法を用いた。これらは非階層的クラスタリングの代表手法である k -means 法の発展手法であり、どちらもデータセットに応じて最適な分割クラスター数が自動推定されるという特徴を有している。

x -means 法と Affinity Propagation では計算アルゴリズムが大きく異なり、同じデータセットに対して 2 つの手法を適用すると、異なる解が得られる場合が多い。本付録では、 k -means 法、 x -means 法、Affinity Propagation のそれぞれの特徴をまとめた上で、各手法を同じデータセットに対して適用し、その結果から各手法を比較する。

表 B.1 非階層的クラスタリング手法の比較

	<i>k</i> -means 法	<i>x</i> -means 法	Affinity Propagation
重要パラメータ	<ul style="list-style-type: none">• 分割クラスタ数• 実行回数	<ul style="list-style-type: none">• 1 回目のクラスタリング処理で生成するクラスタ数 (デフォルトは 2)	<ul style="list-style-type: none">• 嗜好度 (Preference)• 減衰係数 (Damping factor)
利点	<ul style="list-style-type: none">• アルゴリズムが簡単 <ul style="list-style-type: none">• クラスタ数をパラメータとして与える必要がある• 結果が初期クラスタに依存するため、複数回実行する必要がある• 初期クラスタによっては、局所解に陥る• 各クラスタの形状が超球状でクラスタ内のデータ数がどれもほぼ等しいという仮定を基にしているため、この仮定に反する構造の抽出が困難 [208]	<ul style="list-style-type: none">• クラスタ数が自動で決定される	<ul style="list-style-type: none">• クラスタ数が自動で決定される• 計算結果がロバスト <ul style="list-style-type: none">• <i>k</i>-means 法をベースとしているため、<i>k</i>-means 法の欠点を引き継がれている• 全データ点間で複数回メッセージを交換するため、計算コストが極めて大きい• パラメータ依存性が高い

各手法の比較表を表 B.1 に示す。 k -means 法は、比較的単純なアルゴリズムであるにも関わらず良好な結果が得られることから、幅広い分野で用いられてきた。しかし、 k -means 法には多くの問題点があることが知られており、その最たるものが分割クラスタ数をパラメータとして与える必要があるということである。そして、この問題点を解決するクラスタリング手法として提案されたのが x -means 法と Affinity Propagation である。しかし、 x -means 法と Affinity Propagation にはまたそれぞれ別の問題がいくつか存在している。

x -means 法は、データセットに対して k -means 法を再帰的に適用し、尤度（厳密には BIC）の増減をもとにクラスタ数を調整する手法である。しかし、 x -means 法は k -means 法をベースとした手法であるため、 k -means 法に存在したいくつかの問題点が引き継がれている。例えば、 k -means 法ではランダムに決定される初期クラスタによって計算結果が変化するため、最適解を得るためには同じデータセットに対して k -means 法を複数回適用する必要があるが、これは x -means 法でも同様であり、安定した結果を得るためには各反復処理の中で k -means 法を複数回適用する必要がある。また、 k -means 法は各クラスタのデータ構造がほぼ等しいという仮定の下に計算されるため、図 B.1 に示したようなデータセットに対して k -means 法を適用すると誤ったクラスタリング結果が得られる。そして、このように k -means 法で k の値を正確に設定した場合でも正確な解が得られないデータセットの場合には、 x -means 法でも良好な結果が得られない。 x -means 法には分割クラスタ数を調整するためのパラメータとして最初のクラスタリング処理で生成するクラスタ数 ik があるが、通常は全てのクラスタ数に対応するために $ik = 2$ として計算する。

Affinity Propagation は、 k -means 法とは全く異なるアプローチに基いてクラスタリングを行う手法である。Affinity Propagation では k -means 法のような初期クラスタ設定を行う必要がないことから、計算結果のロバスト性が高い。ただし、Affinity Propagation では全てのデータ点間で情報のやりとりを複数回行うため、計算コストが非常に大きくなるという問題があり、適用できるデータセットの大きさには制限がある。また、Affinity Propagation のパラメータの 1 つである嗜好度は、生成されるクラスタ数やクラスタリング結果に大きな影響を及ぼす一方で、最適なクラスタリング結果を得るための値を推定することは非常に難しいとされている [77]。

ここで、2 章における節位推定および 3 章における個別果実検出に対して 3 つのクラスタリング手法を適用した結果をそれぞれ図 B.2 と図 B.3 に示す。まず、節位推定の結果では k -means 法と Affinity Propagation を適用した場合で節位推定が適切になされていることがわかる。一方で、Affinity Propagation と比べて少数のクラスタへ分割する傾向のある x -means 法を用いた場合では、分割クラスタ数が 2 となり誤った節位が推定されている。この結果は、 ik の値を変更しても改善は

表 B.2 各クラスタリング手法の計算時間 [秒]

	k -means 法	x -means 法	Affinity Propagation	データ点数
節位推定	0.08	0.22	0.52	91
個別果実検出	0.22	0.51	11.85	920

見られなかった。また、個別果実検出の結果では Affinity Propagation を用いた場合でのみ、図中左にある果実を検出することができていないことがわかる。これは、Affinity Propagation は x -means 法と比べて多くのクラスタを生成する傾向があり、その結果として反射領域の画素が複数のクラスタに分割されたためである。ただし、図 B.4 に示すように嗜好度をデフォルト値よりも小さくして生成クラスタ数を少なくすることで、Affinity Propagation を個別果実検出にも利用できるようになる。しかしながら、果実は外観のばらつきが大きく、画像によって最適な嗜好度が異なるため、パラメータ依存性の高い Affinity Propagation は個別果実検出処理には不向きであると言える。

各手法における節位推定および個別果実検出の計算に要した時間を表 B.2 にまとめた。データセットに対して再帰的に k -means 法を実行する x -means 法では、 k -means 法と比べて計算時間が数倍になった。また、Affinity Propagation では他の 2 手法よりも計算時間がさらに長く、さらに全データ点間でメッセージを交換するため、データ点数が増加することで計算時間が急激に増加することが確認された。計算コストの面からも、入力データが画像であるためにデータ点数が大きくなる個別果実検出に対して Affinity Propagation は不向きであると言える。

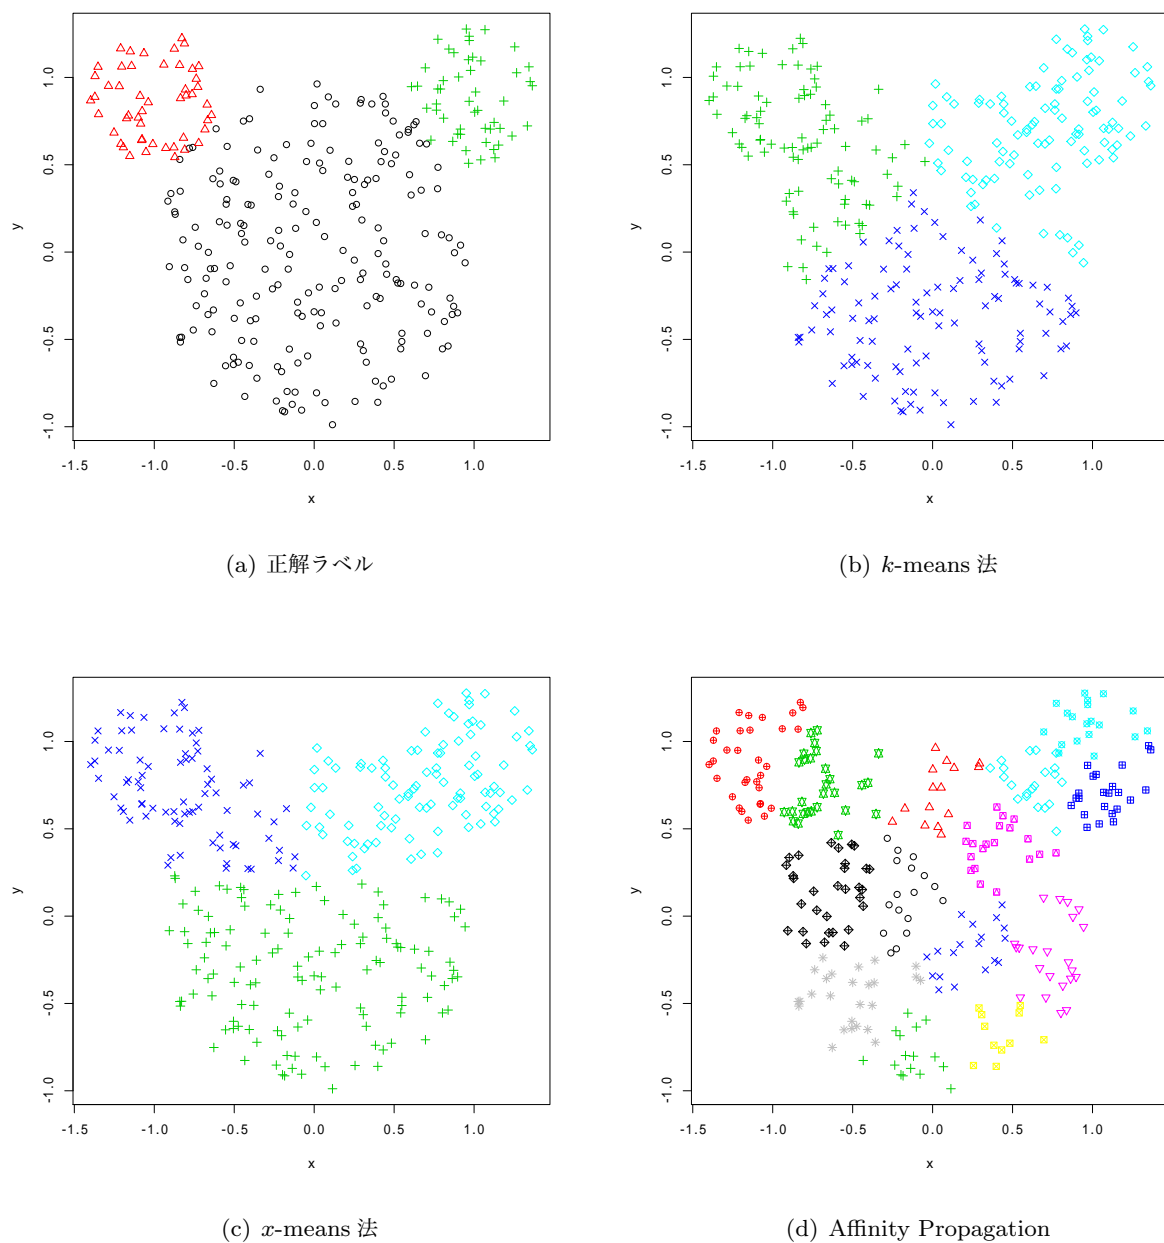








図 B.1 マウスデータセットに対して各手法を適用した結果。同じシンボル、同じ色で示したデータ点が同じクラスに属することを意味する。3つのクラスのうち、1つだけが極端に大きなデータ数を持つため、 k -means 法や x -means 法を適用すると境界線がデータ数の大きいクラス側に移動してしまう。

(a) k -means 法 ($k = 4$)(b) x -means 法

(c) Affinity Propagation

図 B.2 各クラスタリング手法を用いた検出節の節位推定。○と×はそれぞれ検出節と実際の節の位置、実線は検出節から推定された節直線、破線は実際の節直線を表す。Affinity Propagation と比べて少ないクラスタを生成する x -means 法では、節位推定がうまくいっていない。

(a) 入力画像（複数果実領域）。画素数は 20×46 。(b) k -means 法 ($k = 10$)(c) x -means 法

(d) Affinity Propagation

図 B.3 各クラスタリング手法を用いた複数果実領域からの個別果実検出。(b)–(d) は、上がクラスタリング結果、下が平均値が最大のクラスタだけを抽出した結果を表す。Affinity Propagation では、反射領域が複数のクラスタに分類されてしまうため、果実検出に失敗している。

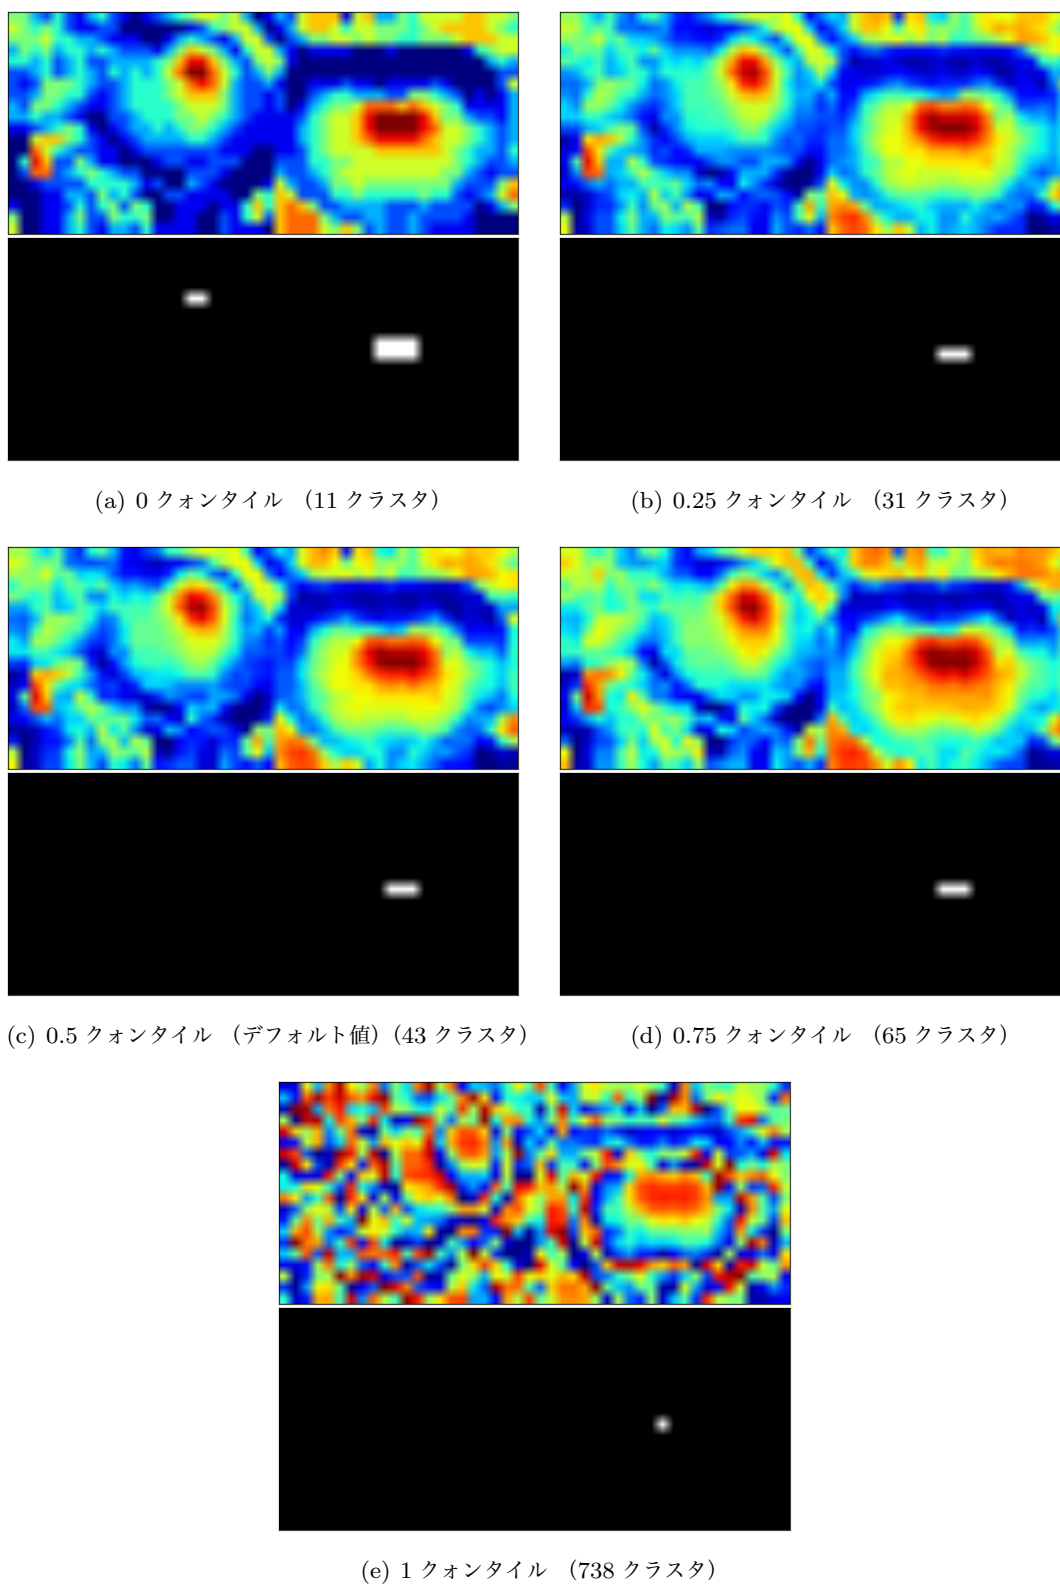


図 B.4 Affinity Propagation による複数果実領域からの個別果実検出。嗜好度を小さくすることで生成クラスタ数が減少し、全果実の反射領域を抽出できるようになる。

摘要

本研究「画像解析と機械学習によるトマトの自動生育診断および高速フェノタイピングに関する研究」は、通常の栽培条件下にあるトマトについて、高速な生育診断・作物表現型評価手法の確立を目的に実施されたものである。

近年、我が国の農業では、環境保全や栽培技術の高度化といった観点から、精密農業への関心が高まってきた。精密農業において基盤となるのは、圃場における作物の生育状態の空間的・時間的ばらつきを効率的に把握する技術である。また、そのための技術は遺伝子解析の高速化と低コスト化が進む一方で、表現型解析に関する技術の発展が立ち遅れている育種分野においてもその需要が高まりつつある。そのため、高速フェノタイピングに関する研究開発が急速に活発化し、中でも、表現型の多くが目視による評価がなされていることから、それを代替する画像解析の応用が幅広く進みつつある。しかし、これまでに開発されてきた画像による高速フェノタイピングの技術の多くは特別な実験環境での利用を条件としており、実圃場での利用は想定されていない。実圃場では光条件の変化や不均一性などにより、画像から対象作物の表現型に関する情報を抽出することは容易ではない。そのため、実圃場における画像による高速フェノタイピング技術の開発は大きな課題の1つとして未だ残されている。

本研究の目的は、実圃場で撮影された作物画像から生育状態に関わる情報を抽出するための画像解析技術を開発し、精密農業や育種の効率化に向けて実用化の可能性を見出すことにある。対象作物には、品質が重要視され精密な管理が求められるトマトを用いる。トマトに関する多様な評価形質の中から、栽培ステージを生育初期、着果期以降、収穫後の3つに分け、各栽培ステージにおいて計測対象とする形質を、育種開発、生育診断などにおいて重要とされる形質の中から選抜し、それらの計測を自動化するための技術を開発するとともに、開発技術のトマトの他の形質や他の作物への応用性について考察する。

以下、本論文における各章の概要を説明する。

第1章では、育種面と栽培面の2つの観点から見た研究背景について述べ、本研究の目的を明確に

した。

第2章では、トマトの生育初期における重要な生育指標である本葉の節間距離に着目し、栽培施設内で撮影した生育初期の樹体画像から本葉の節間距離を推定するための解析手法を開発した。開発手法は節検出、節位推定、節間距離推定の3段階の処理によって構成される。節検出処理では、画像特徴量の機械学習によって画像の分割条件を決定するため、異なる個体に適用する場合でも画像輝度の閾値の調整を要さなかった。また、一般物体認識手法を適用することで多くの誤検出が削除され、節検出の結果が大幅に改善された。検出節の節位推定には Affinity Propagation というクラスタリング手法を採用したため、最終的な節数が異なる個体を解析する場合でもパラメータの調整を要さなかった。さらに、検出節のクラスタリング結果に対して線形回帰を適用することで、誤検出節による節間距離推定への影響の最小化、および未検出節の補間が可能であることが確認された。以上の結果を用いることで、節間距離についても高精度で推定可能であることが確認された。また、時系列画像の連続的な解析を可能にすることで、時系列上での新たな形質評価への道を示すことができた。

第3章では、果菜類における最も重要な形質の1つとしてあげられる着果数の自動計測を目的とし、栽培施設内で撮影した着果期以降の樹体画像から果実を検出するための解析手法を開発した。第2章と同様、開発手法では、機械学習によって生成された分類モデルを元に画像の分割条件を決定するため、作物の状態が異なる複数の樹体画像から果実検出を行う際にも画像輝度の閾値調整を要さなかった。また、熟果、未熟果に加えて、外観特徴上の問題から可視画像解析による検出が難しいとされてきた幼果についても高精度で検出できた。さらに、開発手法では最初に画素ベースでの画像分割を行った上でその他の処理を施すため、樹体画像の解析において深刻な問題となるオクルージョンの問題も解決された。栽培ベッドのパノラマ画像の解析結果では、開発手法によって栽培ベッド内の着果数分布を的確に把握できることが確認された。この結果から、開発手法の収量マップ生成への利用可能性が示された。

第4章では、収穫後のトマト果実の外観特徴を定量評価するための画像解析技術を開発した。開発技術によって、果実の外観特徴を低次元の特徴量で表現できることに加え、従来の定性的な外観特徴指標を定量値で表すことが可能であった。また、得られた外観特徴量を用いて品種間の多重比較検定を行った結果では、ほぼ全ての品種間で有意な差が認められた。この結果は、本研究の外観特徴量が各品種における外観特徴の微細な差異を的確に捉えていたことを示唆している。さらに、得られた特徴量を用いることで、品種間の外観特徴上の関係性を定量的に把握することができた。この結果から、開発手法は特に果実の外観品質評価や育種分野の遺伝子解析などにおける利用価値が高いと考えられた。

第5章では、本研究で栽培ステージ別に開発した手法について、トマトに関する幅広い形質調査項目の中で位置づけるとともに、それら手法の他の形質評価へ幅広く応用できることを考察した。また、残された形質についても高速な評価方法について精査し、将来のトマトにおける総合的な生育診断や高速フェノタイピングを展望するとともに、他の作物への応用性についても考察した。

謝辞

本研究は、東京大学 大学院 農学生命科学研究科 農学国際専攻 国際生態系管理研究室において、二宮正士 教授の多大なるご指導の下遂行されたものである。本研究の実施ならびに本論文のとりまとめにあたり、終始適切なご指導、ご鞭撻を賜り、また多大なる御校閲の労を賜った二宮正士 教授に心から感謝申し上げる。

三重大学 大学院 生物資源学研究科 資源循環学専攻 食・環境・文化情報学研究室 亀岡孝治 教授には、学部・修士課程から東京大学 大学院への移籍後までの長きに渡って、親身にご指導・ご助言をいただいた。また、本研究をまとめるにあたり、適切なご助言と激励を賜り、多大なる御校閲の労をとっていただいた。ここに深謝の意を表する。

本研究をまとめるにあたり、深遠なるご助言と温かい激励を賜り、また御校閲の労を賜った東京大学 大学院 農学生命科学研究科 小林和彦 教授、溝口勝 教授、河鰭実之 教授に深く感謝申し上げます。

東京大学 大学院 農学生命科学研究科 農学国際専攻 国際生態系管理研究室 郭威 特任研究員には先輩研究者として、また同じ研究課題に取り組む仲間として、研究の方向性や解析手法についての多大なご助言をいただいた。また、同研究室の Dhanachandran Sudharsan 特任研究員、西岡一洋 特任研究員、Elisa Azura Binti Azman 氏、棚田大介 氏、日比野友博 氏、伊藤大朗 氏、陳泰伸 氏、井上智也 氏には、様々な研究分野の視点から貴重なご意見を賜るとともに、公私にわたって暖かくサポートしていただいた。加えて、ここにお名前を記すことができなかった生態調和農学機構の教職員、研究員、卒業生、現役生の方々にも様々な面でご協力いただいた。心から感謝申し上げます。

独立行政法人 農業・食品産業技術総合研究機構 野菜茶業研究所 東出忠桐 主任研究員、岡山大学 大学院 環境生命科学研究科 安場健一郎 准教授（当時 独立行政法人 農業・食品産業技術総合研究機構 野菜茶業研究所 主任研究員）、生態調和農学機構技術部には、解析試料であるトマトの栽培および撮影実験にご協力いただいた。ここに深く感謝申し上げます。

独立行政法人 農業・食品産業技術総合研究機構 中央農業総合研究センター 深津時広 主任研究員、独立行政法人 農業・食品産業技術総合研究機構 近畿中国四国農業研究センター 黒崎秀仁 主任研究

員には撮影実験のデザインや撮影装置の開発に関して多くの貴重なご助言をいただいた。ここに深く感謝申し上げる。

ソフトバンクモバイル株式会社 IT サービス開発本部 戸上崇 氏には、日頃の生活態度などについての貴重なご助言、さらには博士課程修了後の進路についてもご配慮いただいた。ここに感謝の意を表する。

また、本研究を進めるにあたり、ご支援、ご協力を頂きながら、ここにお名前を記すことができなかった多くの方々に心より感謝申しあげる。

なお、本研究の一部は科学研究費補助金（研究課題番号: 21380161）、知財活用促進ハイウェイ「大学特許価値向上支援」、農林水産省・ゲノム情報を活用した農畜産物の次世代生産基盤技術の開発プロジェクト（NGB-3002, NGB-3003）、東京大学ソーシャル ICT グローバル・クリエイティブリーダー育成プログラムによる助成を受けて実施されたものである。

最後に、社会的にも人間的にも未熟な私を終始支え、博士課程への進学、本研究の遂行、そして博士論文の執筆を応援してくれた家族、恋人、友人に深く深く感謝申し上げる。

参考文献

- [1] Aggelopoulou, A. D., Bochtis, D., Fountas, S., Swain, K. C., Gemtos, T. A., and Nanos, G. D. (2010) “Yield prediction in apple orchards based on image processing,” *Precision Agriculture*, Vol. 12, No. 3, pp. 448–456, URL: <http://link.springer.com/10.1007/s11119-010-9187-0>, DOI: <http://dx.doi.org/10.1007/s11119-010-9187-0>.
- [2] Aguzzi, J., Costa, C., Fujiwara, Y., Iwase, R., Ramirez-Llorda, E., and Menesatti, P. (2009) “A novel morphometry-based protocol of automated video-image analysis for species recognition and activity rhythms monitoring in deep-sea fauna,” *Sensors*, Vol. 9, No. 11, pp. 8438–8455, URL: <http://www.mdpi.com/1424-8220/9/11/8438/htm>, DOI: <http://dx.doi.org/10.3390/s91108438>.
- [3] AMAZONE (2013) “BoniRob Forschung zur Feldrobotik,” URL: <http://www.amazone.de/1857.asp>, accessed on 2015-03-01.
- [4] Andrade-Sanchez, P., Gore, M. A., Heun, J. T., Thorp, K. R., Carmo-Silva, A. E., French, A. N., Salvucci, M. E., and White, J. W. (2014) “Development and evaluation of a field-based high-throughput phenotyping platform,” *Functional Plant Biology*, Vol. 41, No. 1, p. 68, URL: http://www.publish.csiro.au/view/journals/dsp_journal_fulltext.cfm?nid=102&f=FP13126, DOI: <http://dx.doi.org/10.1071/FP13126>.
- [5] Araus, J. L. and Cairns, J. E. (2013) “Field high-throughput phenotyping: the new crop breeding frontier,” *Trends in plant science*, pp. 1–10, URL: <http://www.ncbi.nlm.nih.gov/pubmed/24139902>, DOI: <http://dx.doi.org/10.1016/j.tplants.2013.09.008>.
- [6] Arefi, A. and Motlagh, A. (2013) “Development of an expert system based on wavelet transform and artificial neural networks for the ripe tomato harvesting robot,” *Australian Journal of Crop Science*, Vol. 7, No. 5, pp. 699–705.
- [7] Bai, J., Zhao, X., Qiang, X., and Yang, Y. (2000) “Study on extraction of computer vision

- feature of conifer seedling,” *Journal of Northeast Forestry University*, Vol. 28, No. 5, pp. 94–96, URL: <http://www.cabdirect.org/abstracts/20013168656.html;jsessionid=3F049E850E2A84D67D2DBA2FEF9098ED?freeview=true#>.
- [8] Bay, H., Tuytelaars, T., and Van Gool, L. (2006) “SURF: Speeded up robust features,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 404–417.
- [9] Bertram, L. and Karlsen, P. (1994) “Patterns in stem elongation rate in chrysanthemum and tomato plants in relation to irradiance and day/night temperature,” *Scientia Horticulturae*, Vol. 58, No. 1-2, pp. 139–150, URL: <http://www.sciencedirect.com/science/article/pii/0304423894901341>, DOI: [http://dx.doi.org/10.1016/0304-4238\(94\)90134-1](http://dx.doi.org/10.1016/0304-4238(94)90134-1).
- [10] Biederman, I. (1985) “Human image understanding: Recent research and a theory,” *Computer Vision Graphics and Image Processing*, Vol. 32, pp. 29–73, DOI: [http://dx.doi.org/10.1016/0734-189x\(85\)90002-7](http://dx.doi.org/10.1016/0734-189x(85)90002-7).
- [11] Bongiovanni, R. and Lowenberg-Deboer, J. (2004) “Precision Agriculture and Sustainability,” *Precision Agriculture*, Vol. 5, No. 4, pp. 359–387, URL: <http://link.springer.com/10.1023/B:PRAG.0000040806.39604.aa>, DOI: <http://dx.doi.org/10.1023/B:PRAG.0000040806.39604.aa>.
- [12] Bosch, A., Zisserman, A., and Muñoz, X. (2008) “Scene Classification Using a Hybrid Generative/Discriminative Approach,” *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 30, No. 4, pp. 712–727, DOI: <http://dx.doi.org/10.1109/TPAMI.2007.70716>.
- [13] Bosch, A., Zisserman, A., Mu, X., and Muñoz, X. (2007) “Image classification using random forests and ferns,” in *ICCV*, pp. 1–8, URL: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4409066, DOI: <http://dx.doi.org/10.1109/ICCV.2007.4409066>.
- [14] Breiman, L., Friedman, J. H., Olshen, R. A., and Stone, C. J. (1984) *Classification and Regression Trees*, Vol. 5: Wadsworth & Brooks/Cole Advanced Books & Software, pp.95–96, URL: <http://www.ncbi.nlm.nih.gov/pubmed/21514355>, DOI: <http://dx.doi.org/10.1371/journal.pone.0015807>.

- [15] Breiman, L. (2001) "Random Forests," *Machine Learning*, Vol. 45, No. 1, pp. 5–32, URL: <http://dx.doi.org/10.1023/A:1010933404324>, DOI: <http://dx.doi.org/10.1023/a:1010933404324>.
- [16] Brewer, M. T., Lang, L., Fujimura, K., Dujmovic, N., Gray, S., and van der Knaap, E. (2006) "Development of a controlled vocabulary and software application to analyze fruit shape variation in tomato and other plant species," *Plant physiology*, Vol. 141, No. 1, pp. 15–25, URL: <http://www.plantphysiol.org/content/141/1/15>, DOI: <http://dx.doi.org/10.1104/pp.106.077867>.
- [17] Brosnan, T. and Sun, D.-W. (2004) "Improving quality inspection of food products by computer vision: a review," *Journal of Food Engineering*, Vol. 61, No. 1, pp. 3–16, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0260877403001833>, DOI: [http://dx.doi.org/10.1016/S0260-8774\(03\)00183-3](http://dx.doi.org/10.1016/S0260-8774(03)00183-3).
- [18] Bylesjö, M., Segura, V., Soolanayakanahally, R. Y., Rae, A. M., Trygg, J., Gustafsson, P., Jansson, S., and Street, N. R. (2008) "LAMINA: a tool for rapid quantification of leaf size and shape parameters," *BMC plant biology*, Vol. 8, No. 1, pp. 1–9, URL: <http://www.biomedcentral.com/1471-2229/8/82>, DOI: <http://dx.doi.org/10.1186/1471-2229-8-82>.
- [19] Cabrera-Bosquet, L., Crossa, J., von Zitzewitz, J., Serret, M. D., and Araus, J. L. (2012) "High-throughput phenotyping and genomic selection: the frontiers of crop breeding converge," *Journal of integrative plant biology*, Vol. 54, No. 5, pp. 312–320, URL: <http://www.ncbi.nlm.nih.gov/pubmed/22420640>, DOI: <http://dx.doi.org/10.1111/j.1744-7909.2012.01116.x>.
- [20] Cao, Y., Jiang, Y., Gao, H., Chen, H., Fang, X., Mu, H., and Tao, F. (2014) "Development of a model for quality evaluation of litchi fruit," *Computers and Electronics in Agriculture*, Vol. 106, pp. 49–55, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914001264>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.05.003>.
- [21] Chaivivatrakul, S. and Dailey, M. (2014) "Texture-based fruit detection," *Precision Agriculture*, Vol. 15, No. 6, pp. 662–683, URL: <http://dx.doi.org/10.1007/s11119-014-9361-x>, DOI: <http://dx.doi.org/10.1007/s11119-014-9361-x>.
- [22] Chatfield, K., Lempitsky, V., Vedaldi, A., and Zisserman, A. (2011) "The devil is in

- the details: an evaluation of recent feature encoding methods,” in Hoey, J., McKenna, S., and Trucco, E. eds. *BMVC*, pp. 76.1–76.12, Dundee, Scotland: BMVA Press, URL: <http://dx.doi.org/10.5244/C.25.76>.
- [23] Chauhan, A. P. S. and Singh, A. P. (2012) “Intelligent Estimator for Assessing Apple Fruit Quality,” *International Journal of Computer Applications*, Vol. 60, No. 5, pp. 35–41.
- [24] Chen, C., Liaw, A., and Breiman, L. (2004) “Using random forest to learn imbalanced data,” Technical report, Department of Statistics, University of California, pp. 1–12.
- [25] Clark, R. T., MacCurdy, R. B., Jung, J. K., Shaff, J. E., McCouch, S. R., Aneshansley, D. J., and Kochian, L. V. (2011) “Three-dimensional root phenotyping with a novel imaging and software platform,” *Plant physiology*, Vol. 156, No. 2, pp. 455–465, URL: <http://www.plantphysiol.org/content/156/2/455.full>, DOI: <http://dx.doi.org/10.1104/pp.110.169102>.
- [26] Clement, J., Novas, N., Gazquez, J.-A., and Manzano-Agugliaro, F. (2012) “High speed intelligent classifier of tomatoes by colour, size and weight,” *Spanish Journal of Agricultural Research*, Vol. 10, No. 2, pp. 314–325, URL: <http://revistas.inia.es/index.php/sjar/article/view/1994>.
- [27] Clement, J., Novas, N., Gazquez, J.-A., and Manzano-Agugliaro, F. (2013) “An active contour computer algorithm for the classification of cucumbers,” *Computers and Electronics in Agriculture*, Vol. 92, pp. 75–81, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169913000215>, DOI: <http://dx.doi.org/10.1016/j.compag.2013.01.006>.
- [28] Cohen, Y., Alchanatis, V., Sela, E., Saranga, Y., Cohen, S., Meron, M., Bosak, A., Tsipris, J., Ostrovsky, V., Orollov, V., Levi, A., and Brikman, R. (2014) “Crop water status estimation using thermography: multi-year model development using ground-based thermal images,” *Precision Agriculture*, pp. 1–19, URL: <http://link.springer.com/10.1007/s11119-014-9378-1>, DOI: <http://dx.doi.org/10.1007/s11119-014-9378-1>.
- [29] Comar, A., Burger, P., de Solan, B., Baret, F., Daumard, F., and Hanocq, J.-F. (2012) “A semi-automatic system for high throughput phenotyping wheat cultivars in-field conditions: description and first results,” *Functional Plant Biology*, Vol. 39, No. 11, pp. 914–924, URL: http://www.publish.csiro.au/view/journals/dsp_journal_fulltext.cfm?nid=102&f=FP12065, DOI: <http://dx.doi.org/10.1071/FP12065>.

- [30] Costa, C., Antonucci, F., Pallottino, F., Aguzzi, J., Sun, D.-W., and Menesatti, P. (2011) “Shape analysis of agricultural products: a review of recent research advances and potential application to computer vision,” *Food and Bioprocess Technology*, Vol. 4, No. 5, pp. 673–692.
- [31] Csurka, G., Dance, C. R., Fan, L., Willamowski, J., and Bray, C. (2004) “Visual categorization with bags of keypoints,” in *Proceedings of the ECCV International Workshop on Statistical Learning in Computer Vision*, pp. 59–74, URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.72.604>.
- [32] Darrigues, A., Hall, J., Knaap, E. V. D., Francis, D. M., Dujmovic, N., and Gray, S. (2008) “Tomato Analyzer-color Test : A New Tool for Efficient Digital Phenotyping,” *Journal of the American Society for Horticultural Science*, Vol. 133, No. 4, pp. 579–586, URL: <http://journal.ashspublications.org/content/133/4/579.abstract>.
- [33] Davis, P. F. (1991) “Orientation-independent recognition of chrysanthemum nodes by an artificial neural network,” *Computers and Electronics in Agriculture*, Vol. 5, No. 4, pp. 305–314, URL: <http://www.sciencedirect.com/science/article/pii/016816999190011W>, DOI: [http://dx.doi.org/http://dx.doi.org/10.1016/0168-1699\(91\)90011-W](http://dx.doi.org/http://dx.doi.org/10.1016/0168-1699(91)90011-W).
- [34] Dey, D., Mummert, L., and Sukthankar, R. (2012) “Classification of plant structures from uncalibrated image sequences,” in *2012 IEEE Workshop on the Applications of Computer Vision (WACV)*, pp. 329–336, Colorado, USA: Ieee, URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6163017>, DOI: <http://dx.doi.org/10.1109/WACV.2012.6163017>.
- [35] Diago, M.-P., Correa, C., Millán, B., Barreiro, P., Valero, C., and Tardaguila, J. (2012) “Grapevine yield and leaf area estimation using supervised classification methodology on RGB images taken under field conditions,” *Sensors*, Vol. 12, No. 12, pp. 16988–17006, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3571822&tool=pmcentrez&rendertype=abstract>, DOI: <http://dx.doi.org/10.3390/s121216988>.
- [36] Duan, L., Yang, W., Huang, C., and Liu, Q. (2011) “A novel machine-vision-based facility for the automatic evaluation of yield-related traits in rice,” *Plant methods*, Vol. 7, No.

- 1, pp. 1–13, URL: <http://www.plantmethods.com/content/7/1/44>, DOI: <http://dx.doi.org/10.1186/1746-4811-7-44>.
- [37] Everingham, M., Van Gool, L., Williams, C. K. I., Winn, J., and Zisserman, A. (2010) “The Pascal Visual Object Classes (VOC) Challenge,” *International Journal of Computer Vision*, Vol. 88, No. 2, pp. 303–338.
- [38] Farenzena, M., Fusiello, A., and Gherardi, R. (2009) “Structure-and-motion pipeline on a hierarchical cluster tree,” in *2009 IEEE 12th International Conference on Computer Vision Workshops*, pp. 1489–1496, Kyoto, Japan: IEEE, URL: http://ieeexplore.ieee.org/xpl/freeabs_all.jsp?arnumber=5457435, DOI: <http://dx.doi.org/10.1109/ICCVW.2009.5457435>.
- [39] Fei-Fei, L., Fergus, R., and Perona, P. (2007) “Learning generative visual models from few training examples: An incremental Bayesian approach tested on 101 object categories,” *Computer Vision and Image Understanding*, Vol. 106, No. 1, pp. 59–70.
- [40] Fiorani, F. and Schurr, U. (2013) “Future Scenarios for Plant Phenotyping,” *Annual Review of Plant Biology*, Vol. 64, No. 1, pp. 267–291, URL: <http://dx.doi.org/10.1146/annurev-arplant-050312-120137>, DOI: <http://dx.doi.org/10.1146/annurev-arplant-050312-120137>.
- [41] Font, D., Pallejà, T., Tresanchez, M., Teixidó, M., Martinez, D., Moreno, J., and Palacín, J. (2014) “Counting red grapes in vineyards by detecting specular spherical reflection peaks in RGB images obtained at night with artificial illumination,” *Computers and Electronics in Agriculture*, Vol. 108, pp. 105–111, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914001902>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.07.006>.
- [42] Freeman, H. (1974) “Computer Processing of Line-Drawing Images,” *ACM Computing Surveys*, Vol. 6, No. 1, pp. 57–97, URL: <http://doi.acm.org/10.1145/356625.356627>, DOI: <http://dx.doi.org/10.1145/356625.356627>.
- [43] French, A., Ubeda-Tomás, S., Holman, T. J., Bennett, M. J., and Pridmore, T. (2009) “High-throughput quantification of root growth using a novel image-analysis tool,” *Plant physiology*, Vol. 150, No. 4, pp. 1784–1795, URL: <http://www.plantphysiol.org/content/150/4/1784.long>, DOI: <http://dx.doi.org/10.1104/pp.109.140558>.

- [44] Frey, B. J. and Dueck, D. (2007) “Clustering by passing messages between data points,” *Science*, Vol. 315, No. 5814, pp. 972–976, URL: <http://www.ncbi.nlm.nih.gov/pubmed/17218491>, DOI: <http://dx.doi.org/10.1126/science.1136800>.
- [45] Fukatsu, T. (2012) “Possibility of Mobile Robot Field Server,” in *33rd Asia-Pacific Advanced Network*, Chiang Mai, Thailand.
- [46] Furbank, R. T. and Tester, M. (2011) “Phenomics technologies to relieve the phenotyping bottleneck,” *Trends in Plant Science*, Vol. 16, No. 12, pp. 635–644, URL: <http://www.sciencedirect.com/science/article/pii/S1360138511002093>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.tplants.2011.09.005>.
- [47] Furukawa, Y. and Ponce, J. (2010) “Accurate, dense, and robust multiview stereopsis,” *IEEE transactions on pattern analysis and machine intelligence*, Vol. 32, No. 8, pp. 1362–1376, DOI: <http://dx.doi.org/10.1109/TPAMI.2009.161>.
- [48] Geodeme, T., Tuytelaars, T., Vanacker, G., Nuttin, M., and Van Gool, L. (2005) “Omnidirectional sparse visual path following with occlusion-robust feature tracking,” in *OMNIVIS Workshop, ICCV*.
- [49] Golzarian, M. R., Frick, R. A., Rajendran, K., Berger, B., Roy, S., Tester, M., and Lun, D. S. (2011) “Accurate inference of shoot biomass from high-throughput images of cereal plants,” *Plant methods*, Vol. 7, No. 1, pp. 1–11, URL: <http://www.plantmethods.com/content/7/1/2>, DOI: <http://dx.doi.org/10.1186/1746-4811-7-2>.
- [50] Granier, C., Aguirrezabal, L., Chenu, K., Cookson, S. J., Dauzat, M., Hamard, P., Thioux, J.-J., Rolland, G., Bouchier-Combaud, S., Lebaudy, A., Muller, B., Simonneau, T., and Tardieu, F. (2006) “PHENOPSIS, an automated platform for reproducible phenotyping of plant responses to soil water deficit in *Arabidopsis thaliana* permitted the identification of an accession with low sensitivity to soil water deficit,” *The New phytologist*, Vol. 169, No. 3, pp. 623–635, URL: <http://www.ncbi.nlm.nih.gov/pubmed/16411964>, DOI: <http://dx.doi.org/10.1111/j.1469-8137.2005.01609.x>.
- [51] Green, J. M., Appel, H., Rehrig, E. M., Harnsomburana, J., Chang, J.-F., Balint-Kurti, P., and Shyu, C.-R. (2012) “PhenoPhyte: a flexible affordable method to quantify 2D phenotypes from imagery,” *Plant methods*, Vol. 8, No. 1, pp. 1–12, URL: <http://www.plantmethods.com/content/8/1/45>, DOI: <http://dx.doi.org/10.1186/>

- 1746-4811-8-45.
- [52] Guo, W. (2014) “Studies on high-throughput phenotyping by use of time series crop images taken under natural environments,” Ph.D. dissertation, The University of Tokyo.
- [53] Guo, W., Rage, U. K., and Ninomiya, S. (2013) “Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model,” *Computers and Electronics in Agriculture*, Vol. 96, pp. 58–66, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169913000847>, DOI: <http://dx.doi.org/10.1016/j.compag.2013.04.010>.
- [54] Hannan, M. W., Burks, T. F., and Bulanon, D. M. (2009) “A Machine Vision Algorithm Combining Adaptive Segmentation and Shape Analysis for Orange Fruit Detection,” *Agricultural Engineering International: CIGR Journal*, Vol. 11, pp. 1–17.
- [55] Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973) “Textural Features for Image Classification,” *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 3, No. 6, pp. 610–621, URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4309314>, DOI: <http://dx.doi.org/10.1109/TSMC.1973.4309314>.
- [56] Harris, C. and Stephens, M. (1988) “A Combined Corner and Edge Detector,” *Proceedings of the Alvey Vision Conference 1988*, pp. 147–151, URL: <http://www.bmva.org/bmvc/1988/avc-88-023.html>.
- [57] Hartigan, J. A. and Wong, M. A. (1979) “A k-means clustering algorithm,” *Applied Statistics*, Vol. 28, No. 1, pp. 100–108, URL: <http://www.jstor.org/stable/10.2307/2346830>, DOI: <http://dx.doi.org/10.2307/2346830>.
- [58] Hartmann, A., Czauderna, T., Hoffmann, R., Stein, N., and Schreiber, F. (2011) “HTPheno: an image analysis pipeline for high-throughput plant phenotyping,” *BMC bioinformatics*, Vol. 12, No. 1, pp. 1–9, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3113939&tool=pmcentrez&rendertype=abstract>, DOI: <http://dx.doi.org/10.1186/1471-2105-12-148>.
- [59] Hashimoto, A., Suehara, K., and Kameoka, T. (2012) “Quantitative Evaluation of Surface Color of Tomato Fruits Cultivated in Remote Farm Using Digital Camera Images,” *SICE Journal of Control, Measurement, and System Integration*, Vol. 5, No. 1, pp. 18–23.
- [60] Hashimoto, A., Toyoshi, Y., Suehara, K.-i., and Kameoka, T. (2014) “Quantitative Color

- Evaluation of Digital Images Based on Illuminating Spectral Information,” in *Proceedings of the 9th Conference of the Asian Federation for Information Technology in Agriculture*, pp. 200–207, Perth, Australia.
- [61] Hayashi, S., Ota, T., Kubota, K., Ganno, K., and Kondo, N. (2005) “Robotic Harvesting Technology for Fruit Vegetables in Protected Horticultural Production,” in *Information and Technology for Sustainable Fruit and Vegetable Production*, pp. 12–16, Montpellier, France.
- [62] Hinton, G. E. and Salakhutdinov, R. R. (2006) “Reducing the Dimensionality of Data with Neural Networks,” *Science*, Vol. 313, No. 5786, pp. 504–507, URL: <http://www.sciencemag.org/content/313/5786/504.abstract>, DOI: <http://dx.doi.org/10.1126/science.1127647>.
- [63] Hirakawa, H., Shirasawa, K., Kosugi, S., Tashiro, K., Nakayama, S., Yamada, M., Kohara, M., Watanabe, A., Kishida, Y., Fujishiro, T., Tsuruoka, H., Minami, C., Sasamoto, S., Kato, M., Nanri, K., Komaki, A., Yanagi, T., Guoxin, Q., Maeda, F., Ishikawa, M., Kuhara, S., Sato, S., Tabata, S., and Isobe, S. N. (2014) “Dissection of the Octoploid Strawberry Genome by Deep Sequencing of the Genomes of *Fragaria* Species,” *DNA Research*, Vol. 21, No. 2, pp. 169–181, URL: <http://dnaresearch.oxfordjournals.org/content/21/2/169.abstract>, DOI: <http://dx.doi.org/10.1093/dnares/dst049>.
- [64] Houle, D., Govindaraju, D. R., and Omholt, S. (2010) “Phenomics: the next challenge,” *Nature reviews. Genetics*, Vol. 11, No. 12, pp. 855–866, URL: <http://dx.doi.org/10.1038/nrg2897>, DOI: <http://dx.doi.org/10.1038/nrg2897>.
- [65] Hočevár, M., Širok, B., Godeša, T., and Stopar, M. (2013) “Flowering estimation in apple orchards by image analysis,” *Precision Agriculture*, Vol. 15, No. 4, pp. 466–478, URL: <http://link.springer.com/10.1007/s11119-013-9341-6>, DOI: <http://dx.doi.org/10.1007/s11119-013-9341-6>.
- [66] International Rice Genome Sequencing Project (2005) “The map-based sequence of the rice genome,” *Nature*, Vol. 436, No. 7052, pp. 793–800, URL: <http://www.ncbi.nlm.nih.gov/pubmed/16100779>, DOI: <http://dx.doi.org/10.1038/nature03895>.
- [67] Ishioka, T. (2005) “An expansion of X-means for automatically determining the optimal number of clusters,” in *Proceedings of International Conference on Computational Intel-*

- ligence*, pp. 91–96.
- [68] Itseez (2014) “OpenCV,” URL: <http://code.opencv.org/projects/opencv>, accessed on 2015-03-01.
- [69] Iwata, H. and Ukai, Y. (2002) “SHAPE: A Computer Program Package for Quantitative Evaluation of Biological Shapes Based on Elliptic Fourier Descriptors,” *Journal of Heredity*, Vol. 93, No. 5, pp. 384–385, URL: <http://jhered.oxfordjournals.org/cgi/content/long/93/5/384>, DOI: <http://dx.doi.org/10.1093/jhered/93.5.384>.
- [70] Iwata, H., Nesumi, H., Ninomiya, S., Takano, Y., and Ukai, Y. (2002) “The Evaluation of Genotype Environment Interactions of Citrus Leaf Morphology Using Image Analysis and Elliptic Fourier Descriptors,” *Breeding Science*, Vol. 52, No. 4, pp. 243–251, URL: <http://joi.jlc.jst.go.jp/JST.JSTAGE/jsbbs/52.243?from=CrossRef>, DOI: <http://dx.doi.org/10.1270/jsbbs.52.243>.
- [71] Iyer-Pascuzzi, A. S., Symonova, O., Mileyko, Y., Hao, Y., Belcher, H., Harer, J., Weitz, J. S., and Benfey, P. N. (2010) “Imaging and analysis platform for automatic phenotyping and trait ranking of plant root systems,” *Plant physiology*, Vol. 152, No. 3, pp. 1148–1157, URL: <http://www.plantphysiol.org/content/152/3/1148>, DOI: <http://dx.doi.org/10.1104/pp.109.150748>.
- [72] Jannink, J.-L., Lorenz, A. J., and Iwata, H. (2010) “Genomic selection in plant breeding: from theory to practice,” *Briefings in functional genomics*, Vol. 9, No. 2, pp. 166–177, URL: <http://bfg.oxfordjournals.org/cgi/content/long/9/2/166>, DOI: <http://dx.doi.org/10.1093/bfgp/elq001>.
- [73] Jay, S., Rabatel, G., Hadoux, X., Moura, D., and Gorretta, N. (2015) “In-field crop row phenotyping from 3D modeling performed using Structure from Motion,” *Computers and Electronics in Agriculture*, Vol. 110, No. 0, pp. 70–77, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914002609>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.compag.2014.09.021>.
- [74] Jégou, H., Douze, M., Schmid, C., and Pérez, P. (2010) “Aggregating local descriptors into a compact image representation,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 3304–3311.
- [75] Jiu, M., Wolf, C., Garcia, C., and Baskurt, A. (2012) “Supervised Learning and Codebook

- Optimization for Bag-of-Words Models,” *Cognitive Computation*, Vol. 4, No. 4, pp. 409–419.
- [76] Kashihara, K. (2013) “Classification of individually pleasant images based on neural networks with the bag of features,” in *Orange Technologies (ICOT), 2013 International Conference on*, pp. 291–293, DOI: <http://dx.doi.org/10.1109/ICOT.2013.6521215>.
- [77] Kashyap, P. and Ujjainiya, B. (2013) “A Survey On Seeds Affinity Propagation,” *International Journal of Engineering Research and Applications (IJERA) ISSN*, Vol. 3, No. 3, pp. 274–282.
- [78] Khojastehnazh, M., Omid, M., and Tabatabaeefar, A. (2010) “Development of a lemon sorting system based on color and size,” *African Journal of Plant Science*, Vol. 4, No. 4, pp. 122–127.
- [79] Kimura, Y., Yamamoto, K., Togami, T., Hashimoto, A., Kameoka, T., and Yoshioka, Y. (2010) “Construction of the prototype system for the chromatic image analysis using Color Distribution Entropy,” in *SICE Annual Conference 2010*, pp. 2438–2442.
- [80] Klukas, C., Chen, D., and Pape, J.-M. (2014) “Integrated Analysis Platform: An Open-Source Information System for High-Throughput Plant Phenotyping,” *Plant physiology*, Vol. 165, No. 2, pp. 506–518, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=4044849&tool=pmcentrez&rendertype=abstract>, DOI: <http://dx.doi.org/10.1104/pp.113.233932>.
- [81] Kolukisaoglu, U. and Thurow, K. (2010) “Future and frontiers of automated screening in plant sciences,” *Plant Science*, Vol. 178, No. 6, pp. 476–484, URL: <http://www.sciencedirect.com/science/article/pii/S0168945210000804>, DOI: <http://dx.doi.org/10.1016/j.plantsci.2010.03.006>.
- [82] Kondo, N., Ahmad, U., Monta, M., and Murase, H. (2000) “Machine vision based quality evaluation of Iyokan orange fruit using neural networks,” *Computers and Electronics in Agriculture*, Vol. 29, No. 1-2, pp. 135–147, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169900001411>, DOI: [http://dx.doi.org/10.1016/S0168-1699\(00\)00141-1](http://dx.doi.org/10.1016/S0168-1699(00)00141-1).
- [83] Kondo, N., Yamamoto, K., Shimizu, H., Yata, K., Kurita, M., Shiigi, T., Monta, M., and Nishizu, T. (2009) “A Machine Vision System for Tomato Cluster Harvesting Robot,”

- Engineering in Agriculture, Environment and Food*, Vol. 2, No. 2, pp. 60–65, URL: <http://www.sciencedirect.com/science/article/pii/S1881836609800177>, DOI: [http://dx.doi.org/http://dx.doi.org/10.1016/S1881-8366\(09\)80017-7](http://dx.doi.org/http://dx.doi.org/10.1016/S1881-8366(09)80017-7).
- [84] Kondou, H., Itou, H., Ishikawa, H., Motonaga, Y., Hashimoto, A., and Kameoka, T. (1998) “Color Chart for Fruits of Grape ‘Aki Queen’ by Digital Image Processing,” in *Agricultural Information Technology in Asia and Oceania*, pp. 197–202, Wakayama, Japan.
- [85] Kondou, H., Kitamura, H., Nishikawa, Y., Motonaga, Y., Hashimoto, A., Naknishi, K., and Kameoka, T. (2002) “Shape evaluation by digital camera for grape leaf,” in *3rd Asian Conference for Information Technology in Agriculture*, pp. 586–590, Beijing, China, URL: <http://zoushoku.narc.affrc.go.jp/ADR/AFITA/afita/afita-conf/2002/part8/p586.pdf>.
- [86] Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012) “ImageNet Classification with Deep Convolutional Neural Networks,” *Advances In Neural Information Processing Systems*, pp. 1097–1105.
- [87] Kruse, O. M. O., Prats-Montalbán, J. M., Indahl, U. G., Kvaal, K., Ferrer, A., and Futsaether, C. M. (2014) “Pixel classification methods for identifying and quantifying leaf surface injury from digital images,” *Computers and Electronics in Agriculture*, Vol. 108, pp. 155–165, URL: <http://www.sciencedirect.com/science/article/pii/S016816991400194X>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.07.010>.
- [88] Kuhl, F. P. and Giardina, C. R. (1982) “Elliptic Fourier features of a closed contour,” *Computer Graphics and Image Processing*, Vol. 18, No. 3, pp. 236–258, URL: <http://www.sciencedirect.com/science/article/pii/0146664X8290034X>, DOI: [http://dx.doi.org/10.1016/0146-664X\(82\)90034-X](http://dx.doi.org/10.1016/0146-664X(82)90034-X).
- [89] Kurtulmus, F., Lee, W. S., and Vardar, A. (2011) “Green citrus detection using ‘eigenfruit’, color and circular Gabor texture features under natural outdoor conditions,” *Computers and Electronics in Agriculture*, Vol. 78, No. 2, pp. 140–149, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169911001475>, DOI: <http://dx.doi.org/10.1016/j.compag.2011.07.001>.
- [90] Kurtulmus, F., Lee, W. S., and Vardar, A. (2013) “Immature peach detection in colour images acquired in natural illumination conditions using statistical classi-

- fiers and neural network,” *Precision Agriculture*, Vol. 15, No. 1, pp. 57–79, URL: <http://link.springer.com/10.1007/s11119-013-9323-8>, DOI: <http://dx.doi.org/10.1007/s11119-013-9323-8>.
- [91] Lee, H., Kim, M. S., Jeong, D., Delwiche, S. R., Chao, K., and Cho, B.-K. (2014) “Detection of cracks on tomatoes using a hyperspectral near-infrared reflectance imaging system,” *Sensors (Basel, Switzerland)*, Vol. 14, No. 10, pp. 18837–18850, URL: <http://www.mdpi.com/1424-8220/14/10/18837>, DOI: <http://dx.doi.org/10.3390/s141018837>.
- [92] Lee, L. (2000) “Foundations of Statistical Natural Language Processing,” *Computational Linguistics*, Vol. 26, No. 2.
- [93] Leemans, V. and Destain, M.-F. (2004) “A real-time grading method of apples based on features extracted from defects,” *Journal of Food Engineering*, Vol. 61, No. 1, pp. 83–89, URL: <http://www.sciencedirect.com/science/article/pii/S0260877403001894>, DOI: [http://dx.doi.org/10.1016/S0260-8774\(03\)00189-4](http://dx.doi.org/10.1016/S0260-8774(03)00189-4).
- [94] LemnaTech (2013) “Scanalyzer discovery platform,” URL: <http://www.lemnatec.com/products>, accessed on 2015-02-27.
- [95] Leutenegger, S., Chli, M., and Siegwart, R. Y. (2011) “BRISK: Binary Robust invariant scalable keypoints,” in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2548–2555.
- [96] Li, H., Lee, W. S., and Wang, K. (2014) “Identifying blueberry fruit of different growth stages using natural outdoor color images,” *Computers and Electronics in Agriculture*, Vol. 106, pp. 91–101, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914001483>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.05.015>.
- [97] Li, L., Zhang, Q., and Huang, D. (2014) “A Review of Imaging Techniques for Plant Phenotyping,” *Sensors*, Vol. 14, No. 11, pp. 20078–20111, URL: <http://www.mdpi.com/1424-8220/14/11/20078>, DOI: <http://dx.doi.org/10.3390/s141120078>.
- [98] Liming, X. and Yanchao, Z. (2010) “Automated strawberry grading system based on image processing,” *Computers and Electronics in Agriculture*, Vol. 71, pp. S32–S39, URL: <http://linkinghub.elsevier.com/retrieve/pii/S016816990900204X>, DOI: <http://dx.doi.org/10.1016/j.compag.2009.09.013>.
- [99] Lin, P., Chen, Y., and He, Y. (2010) “Identification of Broken Rice Kernels Us-

- ing Image Analysis Techniques Combined with Velocity Representation Method,” *Food and Bioprocess Technology*, Vol. 5, No. 2, pp. 796–802, URL: <http://www.springerlink.com/index/10.1007/s11947-010-0454-x>, DOI: <http://dx.doi.org/10.1007/s11947-010-0454-x>.
- [100] Ling, P. and Ruzhitsky, V. (1996) “Machine Vision Techniques for Measuring the Canopy of Tomato Seedling,” *Journal of Agricultural Engineering Research*, Vol. 65, No. 2, pp. 85–95, URL: <http://www.sciencedirect.com/science/article/pii/S0021863496900827>, DOI: <http://dx.doi.org/10.1006/jaer.1996.0082>.
- [101] Linker, R., Cohen, O., and Naor, A. (2012) “Determination of the number of green apples in RGB images recorded in orchards,” *Computers and Electronics in Agriculture*, Vol. 81, pp. 45–57, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169911002638>, DOI: <http://dx.doi.org/10.1016/j.compag.2011.11.007>.
- [102] Lino, A. C. L., Sanches, J., and Fabbro, I. M. D. (2008) “Image processing techniques for lemons and tomatoes classification,” *Bragantia*, Vol. 67, No. 3, pp. 785–789, URL: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0006-87052008000300029&lng=en&nrm=iso&tlng=en, DOI: <http://dx.doi.org/10.1590/S0006-87052008000300029>.
- [103] Long, Y. (2014) “Blind image quality assessment using compact visual codebooks,” in *The 18th World Congress of CIGR*, Beijing, China.
- [104] López Camelo, A. F. and Gómez, P. A. (2004) “Comparison of color indexes for tomato ripening,” *Horticultura Brasileira*, Vol. 22, No. 3, pp. 534–537, URL: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-05362004000300006&lng=en&nrm=iso&tlng=en, DOI: <http://dx.doi.org/10.1590/S0102-05362004000300006>.
- [105] López-García, F., Andreu-García, G., Blasco, J., Aleixos, N., and Valiente, J.-M. (2010) “Automatic detection of skin defects in citrus fruits using a multivariate image analysis approach,” *Computers and Electronics in Agriculture*, Vol. 71, No. 2, pp. 189–197, URL: <http://linkinghub.elsevier.com/retrieve/pii/S016816991000013X>, DOI: <http://dx.doi.org/10.1016/j.compag.2010.02.001>.
- [106] Lorenz, A. J., Chao, S., Asoro, F. G., Heffner, E. L., Hayashi, T., Iwata, H., Smith, K. P., Sorrells, M. E., and Jannink, J.-L. (2011) “Genomic selection in plant breeding: knowledge

- and prospects,” in *Advances in Agronomy, Volume 110*: Academic Press, 1st edition, pp. 77–123.
- [107] Losos, J. B., Arnold, S. J., Bejerano, G., Brodie, E. D., Hibbett, D., Hoekstra, H. E., Mindell, D. P., Monteiro, A., Moritz, C., Orr, H. A., Petrov, D. a., Renner, S. S., Ricklefs, R. E., Soltis, P. S., and Turner, T. L. (2013) “Evolutionary biology for the 21st century,” *PLoS biology*, Vol. 11, No. 1, p. e1001466, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3539946&tool=pmcentrez&rendertype=abstract>, DOI: <http://dx.doi.org/10.1371/journal.pbio.1001466>.
- [108] Lowe, D. G. (2004) “Distinctive image features from scale-invariant keypoints,” *International Journal of Computer Vision*, Vol. 60, No. 2, pp. 91–110.
- [109] Matas, J., Chum, O., Urban, M., and Pajdla, T. (2004) “Robust wide-baseline stereo from maximally stable extremal regions,” in *Image and Vision Computing*, Vol. 22, pp. 761–767.
- [110] McCarthy, C. L., Hancock, N. H., and Raine, S. R. (2009) “Automated internode length measurement of cotton plants under field conditions,” *Transactions of the ASABE*, Vol. 52, No. 6, pp. 2093–2103.
- [111] Menesatti, P., Angelini, C., Pallottino, F., Antonucci, F., Aguzzi, J., and Costa, C. (2012) “RGB color calibration for quantitative image analysis: the ”3D thin-plate spline” warping approach,” *Sensors*, Vol. 12, No. 6, pp. 7063–7079, URL: <http://www.mdpi.com/1424-8220/12/6/7063/htm>, DOI: <http://dx.doi.org/10.3390/s120607063>.
- [112] Menesatti, P., Costa, C., Antonucci, F., Steri, R., Pallottino, F., and Catillo, G. (2014) “A low-cost stereovision system to estimate size and weight of live sheep,” *Computers and Electronics in Agriculture*, Vol. 103, pp. 33–38, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914000362>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.01.018>.
- [113] Mir, R. R., Zaman-Allah, M., Sreenivasulu, N., Trethowan, R., and Varshney, R. K. (2012) “Integrated genomics, physiology and breeding approaches for improving drought tolerance in crops,” *TAG. Theoretical and applied genetics. Theoretische und angewandte Genetik*, Vol. 125, No. 4, pp. 625–645, URL: <http://www.pubmedcentral.nih.gov/>

- articlerender.fcgi?artid=3405239&tool=pmcentrez&rendertype=abstract, DOI: <http://dx.doi.org/10.1007/s00122-012-1904-9>.
- [114] Mohammed Amean, Z., Low, T., McCarthy, C., and Hancock, N. (2013) “Automatic plant branch segmentation and classification using vesselness measure,” in *Proceedings of the 2013 Australasian Conference on Robotics and Automation (ACRA 2013)*, Australasian Robotics and Automation Association.
- [115] Montes, J., Technow, F., Dhillon, B., Mauch, F., and Melchinger, A. (2011) “High-throughput non-destructive biomass determination during early plant development in maize under field conditions,” *Field Crops Research*, Vol. 121, No. 2, pp. 268–273, URL: <http://www.sciencedirect.com/science/article/pii/S0378429010003400>, DOI: <http://dx.doi.org/10.1016/j.fcr.2010.12.017>.
- [116] Montes, J. M., Melchinger, A. E., and Reif, J. C. (2007) “Novel throughput phenotyping platforms in plant genetic studies,” *Trends in plant science*, Vol. 12, No. 10, pp. 433–436, URL: <http://www.cell.com/article/S1360138507001859/fulltext><http://www.sciencedirect.com/science/article/pii/S1360138507001859>, DOI: <http://dx.doi.org/10.1016/j.tplants.2007.08.006>.
- [117] Moosmann, F., Triggs, B., and Jurie, F. (2007) “Fast Discriminative Visual Codebooks using Randomized Clustering Forests,” *Advances in Neural Information Processing Systems 19*, Vol. 19, pp. 985–992.
- [118] Moshou, D., Bravo, C., West, J., Wahlen, S., McCartney, A., and Ramon, H. (2004) “Automatic detection of ‘yellow rust’ in wheat using reflectance measurements and neural networks,” *Computers and Electronics in Agriculture*, Vol. 44, No. 3, pp. 173–188, URL: <http://www.sciencedirect.com/science/article/pii/S0168169904000705>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.compag.2004.04.003>.
- [119] National Research Council (1997) *Precision Agriculture in the 21st Century: Geospatial and Information Technologies in Crop Management*. National Academies Press, URL: <http://amazon.com/o/ASIN/0309058937/>.
- [120] Ninomiya, S., Sasaki, A., and Takemura, K. (1992) “Evaluation of fineness of wrinkles on husks of malting barley (*Hordeum vulgare* L.) by texture analysis of digital image data,” *Euphytica*, Vol. 64, No. 1-2, pp. 113–121, URL: <http://link.springer.com/article/>

- 10.1007/BF00023544, DOI: <http://dx.doi.org/10.1007/BF00023544>.
- [121] Ninomiya, S. and Nguyen-Cong, V. (1998) "Evaluation of Soybean Plant Shape Based on Tree-Based Models," *Breeding science*, Vol. 48, No. 3, pp. 251–255, URL: <http://ci.nii.ac.jp/naid/110001807909/en/>.
- [122] Nowak, E., Jurie, F., and Triggs, B. (2006) "Sampling strategies for bag-of-features image classification," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 490–503.
- [123] Nuske, S., Achar, S., Bates, T., Narasimhan, S., and Singh, S. (2011) "Yield estimation in vineyards by visual grape detection," in *Proceedings of the 2011 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '11)*, Robotics Institute, Carnegie Mellon University, Pittsburgh, PA, USA, 15213, DOI: <http://dx.doi.org/10.1109/IROS.2011.6095069>.
- [124] Oberti, R., Marchi, M., Tirelli, P., Calcante, A., Iriti, M., and Borghese, A. N. (2014) "Automatic detection of powdery mildew on grapevine leaves by image analysis: Optimal view-angle range to increase the sensitivity," *Computers and Electronics in Agriculture*, Vol. 104, pp. 1–8, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914000611>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.compag.2014.03.001>.
- [125] Okamoto, H. and Lee, W. S. (2009) "Green citrus detection using hyperspectral imaging," *Computers and Electronics in Agriculture*, Vol. 66, No. 2, pp. 201–208, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169909000258>, DOI: <http://dx.doi.org/10.1016/j.compag.2009.02.004>.
- [126] Okamoto, Y., Nguyen, A. T., Yoshioka, M., Iehisa, J. C. M., and Takumi, S. (2013) "Identification of quantitative trait loci controlling grain size and shape in the D genome of synthetic hexaploid wheat lines," *Breeding Science*, Vol. 63, No. 4, pp. 423–429, DOI: <http://dx.doi.org/10.1270/jsbbs.63.423>.
- [127] OpenCV dev team (2014) "Miscellaneous Image Transformations," URL: http://docs.opencv.org/2.4.9/modules/imgproc/doc/miscellaneous_transformations.html#cv2.cvtColor, accessed on 2015-02-27.
- [128] Otsu, N. (1975) "A threshold selection method from gray-level histograms," *Automatica*,

- Vol. 11, No. 285-296, pp. 23–27.
- [129] Pallottino, F., Menesatti, P., Costa, C., Paglia, G., Salvador, F. R., and Lolletti, D. (2009) “Image Analysis Techniques for Automated Hazelnut Peeling Determination,” *Food and Bioprocess Technology*, Vol. 3, No. 1, pp. 155–159, URL: <http://www.springerlink.com/index/10.1007/s11947-009-0211-1>, DOI: <http://dx.doi.org/10.1007/s11947-009-0211-1>.
- [130] Passioura, J. B. (2012) “Phenotyping for drought tolerance in grain crops: when is it useful to breeders?,” *Functional Plant Biology*, Vol. 39, No. 11, pp. 851–859, URL: http://www.publish.csiro.au/view/journals/dsp_journal_fulltext.cfm?nid=102&f=FP12079, DOI: <http://dx.doi.org/10.1071/FP12079>.
- [131] Payne, A., Walsh, K., Subedi, P., and Jarvis, D. (2014) “Estimating mango crop yield using image analysis using fruit at ‘stone hardening’ stage and night time imaging,” *Computers and Electronics in Agriculture*, Vol. 100, pp. 160–167, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169913002810>, DOI: <http://dx.doi.org/10.1016/j.compag.2013.11.011>.
- [132] Payne, A., Walsh, K., Subedi, P., and Jarvis, D. (2013) “Estimation of mango crop yield using image analysis Segmentation method,” *Computers and Electronics in Agriculture*, Vol. 91, pp. 57–64, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169912002669>, DOI: <http://dx.doi.org/10.1016/j.compag.2012.11.009>.
- [133] Pelleg, D. and Moore, A. W. (2000) “X-means: Extending K-means with Efficient Estimation of the Number of Clusters,” in *Proceedings of the Seventeenth International Conference on Machine Learning*, ICML ’00, pp. 727–734, San Francisco, CA, USA: Morgan Kaufmann Publishers Inc. URL: <http://dl.acm.org/citation.cfm?id=645529.657808>.
- [134] Perronnin, F. and Dance, C. (2007) “Fisher kernels on visual vocabularies for image categorization,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.
- [135] Perronnin, F., Sánchez, J., and Mensink, T. (2010a) “Improving the Fisher kernel for large-scale image classification,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, pp. 143–156.
- [136] Perronnin, F., Liu, Y., Sánchez, J., and Poirier, H. (2010b) “Large-scale image retrieval

- with compressed fisher vectors,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 3384–3391.
- [137] Phenospex (2013) “PlantEye 3D Laser Scanner for Plants,” URL: <http://phenospex.com/products/plant-phenotyping/science-planteye-3d-laser-scanner/>, accessed on 2015-02-27.
- [138] PhenoVation (2013) “CropReporter,” URL: <http://www.phenovation.com>, accessed on 2015-02-27.
- [139] Picard, D. and Gosselin, P. H. (2011) “Improving image similarity with vectors of locally aggregated tensors,” in *Proceedings - International Conference on Image Processing, ICIP*, pp. 669–672.
- [140] Pound, M. P., French, A. P., Atkinson, J. A., Wells, D. M., Bennett, M. J., and Pridmore, T. (2013) “RootNav: navigating images of complex root architectures,” *Plant physiology*, Vol. 162, No. 4, pp. 1802–14, URL: <http://www.plantphysiol.org/content/162/4/1802.long>, DOI: <http://dx.doi.org/10.1104/pp.113.221531>.
- [141] Qiao, J., Sasao, A., Shibusawa, S., Kondo, N., and Morimoto, E. (2004) “Mobile fruit grading robot (part 1)-Development of a robotic system for grading sweet peppers,” *Journal of the Japanese Society of Agricultural Machinery*, Vol. 66, No. 2, pp. 113–122, URL: http://jlc.jst.go.jp/JST.Journalarchive/jsam1937/66.2_113?from=Google, DOI: http://dx.doi.org/10.11357/jsam1937.66.2_113.
- [142] Qiao, J., Sasao, A., Shibusawa, S., Kondo, N., and Morimoto, E. (2005) “Mapping Yield and Quality using the Mobile Fruit Grading Robot,” *Biosystems Engineering*, Vol. 90, No. 2, pp. 135–142, URL: <http://www.sciencedirect.com/science/article/pii/S153751100400193X>, DOI: <http://dx.doi.org/10.1016/j.biosystemseng.2004.10.002>.
- [143] R Development Core Team (2011) *R: A Language and Environment for Statistical Computing*, Vienna, Austria: R Foundation for Statistical Computing, URL: <http://www.r-project.org>.
- [144] Rascher, U., Blossfeld, S., Fiorani, F., Jahnke, S., Jansen, M., Kuhn, A. J., Matsubara, S., Martin, L. L. a., Merchant, A., Metzner, R., Müller-Linow, M., Nagel, K. a., Pieruschka, R., Pinto, F., Schreiber, C. M., Temperton, V. M., Thorpe, M. R., Dusschoten, D. V.,

- Van Volkenburgh, E., Windt, C. W., and Schurr, U. (2011) “Non-invasive approaches for phenotyping of enhanced performance traits in bean,” *Functional Plant Biology*, Vol. 38, No. 12, pp. 968–983, URL: <http://www.publish.csiro.au/?paper=FP11164>, DOI: <http://dx.doi.org/10.1071/FP11164>.
- [145] Regunathan, M. and Lee, W. (2005) “Citrus fruit identification and size determination using machine vision and ultrasonic sensors,” in *ASABE Annual International Meeting*, No. 05, Florida, USA, URL: <http://www.phtnet.org/research/download/pdf/wt396.pdf>.
- [146] Reuzeau, C., Frankard, V., Hatzfeld, Y., Sanz, A., Van Camp, W., Lejeune, P., De Wilde, C., Lievens, K., de Wolf, J., Vranken, E., Peerbolte, R., and Broekaert, W. (2006) “Traitmill: a functional genomics platform for the phenotypic analysis of cereals,” *Plant Genetic Resources: characterization and utilization*, Vol. 4, No. 1, pp. 20–24, URL: http://journals.cambridge.org/abstract_S1479262106000049, DOI: <http://dx.doi.org/10.1079/PGR2005104>.
- [147] Rigney, M. P. and Kranzler, G. A. (1988) “Machine Vision for Grading Southern Pine SeedHngs,” *Transactions of the ASAE*, Vol. 31, No. 2, pp. 642–646.
- [148] Rosten, E., Porter, R., and Drummond, T. (2010) “Faster and better: A machine learning approach to corner detection,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 32, No. 1, pp. 105–119.
- [149] Rublee, E., Rabaud, V., Konolige, K., and Bradski, G. (2011) “ORB: An efficient alternative to SIFT or SURF,” in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2564–2571.
- [150] Ruiz-Ruiz, G., Gómez-Gil, J., and Navas-Gracia, L. (2009) “Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA),” *Computers and Electronics in Agriculture*, Vol. 68, No. 1, pp. 88–96, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169909000738>, DOI: <http://dx.doi.org/10.1016/j.compag.2009.04.009>.
- [151] Safren, O., Alchanatis, V., Ostrovsky, V., and Levi, O. (2007) “Detection Of Green Apples in Hyperspectral Images of Apple-Tree Foliage using Machine Vision,” *Transactions of the ASABE*, Vol. 50, No. 6, pp. 2303–2313, URL: <http://cat.inist.fr/?aModele=>

- afficheN&cpsidt=20030954.
- [152] van de Sande, K. E. A., Gevers, T., and Snoek, C. G. M. (2010) “Evaluating Color Descriptors for Object and Scene Recognition,” *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 32, No. 9, pp. 1582–1596, DOI: <http://dx.doi.org/10.1109/TPAMI.2009.154>.
- [153] Sarkar, N., Little, A., and Wolfe, R. (1984) “Computer vision based system for quality separation of fresh market tomatoes,” *American Society of Agricultural Engineers*, pp. 1714–1718, URL: <http://agris.fao.org/agris-search/search/display.do?f=1987/US/US87015.xml;US8635685>.
- [154] Schieffer, J. and Dillon, C. (2014) “The economic and environmental impacts of precision agriculture and interactions with agro-environmental policy,” *Precision Agriculture*, pp. 1–16, URL: <http://link.springer.com/10.1007/s11119-014-9382-5>, DOI: <http://dx.doi.org/10.1007/s11119-014-9382-5>.
- [155] Sengupta, S. and Lee, W. S. (2014) “Identification and determination of the number of immature green citrus fruit in a canopy under different ambient light conditions,” *Biosystems Engineering*, Vol. 117, pp. 51–61, URL: <http://www.sciencedirect.com/science/article/pii/S1537511013001141>, DOI: <http://dx.doi.org/10.1016/j.biosystemseng.2013.07.007>.
- [156] Sengupta, S. and Lee, W. (2012) “Identification and Determination of the Number of Green Citrus Fruit under Different Ambient Light Conditions,” in *International Conference of Agricultural Engineering CIGR-AgEng2012*, Valencia, Spain, URL: http://cigr.ageng2012.org/images/fotosg/tabla_137_C0380.pdf.
- [157] Shimizu, H. and Heins, R. D. (2000) “Photoperiod and the Difference between Day and Night Temperature Influence Stem Elongation Kinetics in *Verbena bonariensis*,” *J. Amer. Soc. Hort. Sci.*, Vol. 125, No. 5, pp. 576–580, URL: <http://journal.ashspublications.org/content/125/5/576.short>.
- [158] SHRESTHA, B. P., NAGATA, M., and CAO, Q. (2001) “Study on Image Processing for Quality Estimation of Strawberries (Part 1),” *Shokubutsu Kojo Gakkaishi*, Vol. 13, No. 2, pp. 115–122, URL: https://www.jstage.jst.go.jp/article/jshita1991/13/2/13_2_115/_article, DOI: <http://dx.doi.org/10.2525/jshita.13.115>.

- [159] Snavely, N., Seitz, S. M., and Szeliski, R. (2007) “Modeling the World from Internet Photo Collections,” *International Journal of Computer Vision*, Vol. 80, No. 2, pp. 189–210, URL: <http://link.springer.com/10.1007/s11263-007-0107-3>, DOI: <http://dx.doi.org/10.1007/s11263-007-0107-3>.
- [160] Stajanko, D., Lakota, M., and Hočevár, M. (2004) “Estimation of number and diameter of apple fruits in an orchard during the growing season by thermal imaging,” *Computers and Electronics in Agriculture*, Vol. 42, No. 1, pp. 31–42, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169903000863>, DOI: [http://dx.doi.org/10.1016/S0168-1699\(03\)00086-3](http://dx.doi.org/10.1016/S0168-1699(03)00086-3).
- [161] Stajanko, D., Rakun, J., and Blanke, M. (2009) “Modelling Apple Fruit Yield Using Image Analysis for Fruit Colour, Shape and Texture,” *European Journal of Horticultural Science*, Vol. 74, No. 6, pp. 260–267.
- [162] Stajanko, D. and Čmelik, Z. (2005) “Modelling of Apple Fruit Growth by Application of Image Analysis,” *Agriculturae Conspectus Scientificus (ACS)*, Vol. 70, No. 2, pp. 59–64, URL: http://hrcak.srce.hr/index.php?show=clanak&id_clanak=909.
- [163] Tanabata, T., Shibaya, T., Hori, K., Ebana, K., and Yano, M. (2012) “SmartGrain: high-throughput phenotyping software for measuring seed shape through image analysis,” *Plant physiology*, Vol. 160, No. 4, pp. 1871–1880, URL: <http://www.plantphysiol.org/content/160/4/1871.long>, DOI: <http://dx.doi.org/10.1104/pp.112.205120>.
- [164] Tao, Y., Heinemann, P. H., Varghese, Z., Morrow, C. T., and Sommer, H. J. (1995) “Machine vision for color inspection of potatoes and apples,” *Transactions of the ASAE*, Vol. 38, No. 5, pp. 1555–1561, URL: <http://cat.inist.fr/?aModele=afficheN&cpsidt=3705560>.
- [165] Teixidó, M., Font, D., Pallejà, T., Tresanchez, M., Nogués, M., and Palacín, J. (2012) “Definition of linear color models in the RGB vector color space to detect red peaches in orchard images taken under natural illumination,” *Sensors*, Vol. 12, No. 6, pp. 7701–7718, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3435998&tool=pmcentrez&rendertype=abstract>, DOI: <http://dx.doi.org/10.3390/s120607701>.
- [166] The Tomato Genome Consortium (2012) “The tomato genome sequence provides

- insights into fleshy fruit evolution,” *Nature*, Vol. 485, No. 7400, pp. 635–641, URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3378239&tool=pmcentrez&rendertype=abstract>.
- [167] Tisné, S., Serrand, Y., Bach, L., Gilbault, E., Ben Ameer, R., Balasse, H., Voisin, R., Bouchez, D., Durand-Tardif, M., Guerche, P., Chareyron, G., Da Rugna, J., Camilleri, C., and Loudet, O. (2013) “Phenoscope: an automated large-scale phenotyping platform offering high spatial homogeneity,” *The Plant journal : for cell and molecular biology*, Vol. 74, No. 3, pp. 534–544, URL: <http://www.ncbi.nlm.nih.gov/pubmed/23452317>, DOI: <http://dx.doi.org/10.1111/tpj.12131>.
- [168] Tong, J. H., Li, J. B., and Jiang, H. Y. (2013) “Machine vision techniques for the evaluation of seedling quality based on leaf area,” *Biosystems Engineering*, Vol. 115, No. 3, pp. 369–379, URL: <http://www.sciencedirect.com/science/article/pii/S1537511013000305>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.biosystemseng.2013.02.006>.
- [169] Torres-Sánchez, J., Peña, J., a.I. de Castro, and López-Granados, F. (2014) “Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV,” *Computers and Electronics in Agriculture*, Vol. 103, pp. 104–113, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169914000568>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.02.009>.
- [170] Tsai, D., Jing, Y., Liu, Y., A.Rowley, H., Ioffe, S., and M.Rehg, J. (2011) “Large-Scale Image Annotation using Visual Synset,” *Computer Vision (ICCV), 2011 IEEE International Conference on*, pp. 611–618.
- [171] Wachs, J., Stern, H. I., Burks, T., Alchanatis, V., and Bet-Dagan, I. (2009) “Apple detection in natural tree canopies from multimodal images,” in *Proceeding of the Citrus fruit identification and size determination using machine vision and ultrasonic sensors JIAC*, pp. 293–302, Wageningen, Netherlands.
- [172] Walter, A., Scharr, H., Gilmer, F., Zierer, R., Nagel, K. A., Ernst, M., Wiese, A., Virnich, O., Christ, M. M., Uhlig, B., Jünger, S., and Schurr, U. (2007) “Dynamics of seedling growth acclimation towards altered light conditions can be quantified via GROWSCREEN: a setup and procedure designed for rapid optical phenotyping of different plant species,”

- The New phytologist*, Vol. 174, No. 2, pp. 447–455, URL: <http://www.ncbi.nlm.nih.gov/pubmed/17388907>, DOI: <http://dx.doi.org/10.1111/j.1469-8137.2007.02002.x>.
- [173] Wang, H. (2013) “Feature Fusion for Image Classification Based on Affinity Propagation,” *International Journal of Digital Content Technology and its Applications*, Vol. 7, No. 8, pp. 480–487, URL: http://www.aicit.org/jdcta/global/paper_detail.html?jname=JDCTA&q=3210, DOI: <http://dx.doi.org/10.4156/jdcta.vol7.issue8.53>.
- [174] Wang, Q., Nuske, S., Bergerman, M., and Singh, S. (2012) “Design of Crop Yield Estimation System for Apple Orchards Using Computer Vision,” in *2012 ASABE Annual International Meeting*, No. 12, Texas, USA.
- [175] Wang, Q., Nuske, S., Bergerman, M., and Singh, S. (2013) “Automated Crop Yield Estimation for Apple Orchards,” in *Experimental Robotics*, New York, USA: Springer International Publishing, pp. 745–758.
- [176] Weiss, U. and Biber, P. (2011) “Plant detection and mapping for agricultural robots using a 3D LIDAR sensor,” *Robotics and Autonomous Systems*, Vol. 59, No. 5, pp. 265–273, URL: <http://www.sciencedirect.com/science/article/pii/S0921889011000315>, DOI: <http://dx.doi.org/10.1016/j.robot.2011.02.011>.
- [177] Whan, A. P., Smith, A. B., Cavanagh, C. R., Ral, J.-P. F., Shaw, L. M., Howitt, C. A., and Bischof, L. (2014) “GrainScan: a low cost, fast method for grain size and colour measurements,” *Plant Methods*, Vol. 10, No. 1, pp. 1–10, URL: <http://www.plantmethods.com/content/10/1/23>, DOI: <http://dx.doi.org/10.1186/1746-4811-10-23>.
- [178] Xian, W., Jingfeng, B., Baian, L., Xuezheng, Z., Wu, X., Bai, J., Lin, B., and Zhao, X. (1998) “System of Automatic Grading of Conifer Seedling by Computer Vision,” *Journal of Northeast Forestry University*, Vol. 26, No. 4, pp. 32–35, URL: http://en.cnki.com.cn/Article_en/CJFDTOTAL-DBLY804.006.htm.
- [179] Xiang, R., Jiang, H., and Ying, Y. (2014) “Recognition of clustered tomatoes based on binocular stereo vision,” *Computers and Electronics in Agriculture*, Vol. 106, pp. 75–90, URL: <http://www.sciencedirect.com/science/article/pii/S016816991400129X>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.05.006>.
- [180] Xiao, J., Hays, J., Ehinger, K. A., Oliva, A., and Torralba, A. (2010) “Sun database: Large-scale scene recognition from abbey to zoo,” in *Computer vision and pattern recog-*

- niton (CVPR), 2010 IEEE conference on, pp. 3485–3492, IEEE.
- [181] Xiaobo, Z., Jiewen, Z., and Yanxiao, L. (2007) “Apple color grading based on organization feature parameters,” *Pattern Recognition Letters*, Vol. 28, No. 15, pp. 2046–2053, URL: <http://www.sciencedirect.com/science/article/pii/S016786550700181X>, DOI: <http://dx.doi.org/10.1016/j.patrec.2007.06.001>.
- [182] Xiaobo, Z., Jiewen, Z., Yanxiao, L., Jiyong, S., and Xiaoping, Y. (2008) “Apples Shape Grading by Fourier Expansion and Genetic Program Algorithm,” in *2008 Fourth International Conference on Natural Computation*, Vol. 4, pp. 85–90: IEEE, URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4667254>, DOI: <http://dx.doi.org/10.1109/ICNC.2008.703>.
- [183] Xu, G., Zhang, F., Shah, S. G., Ye, Y., and Mao, H. (2011) “Use of leaf color images to identify nitrogen and potassium deficient tomatoes,” *Pattern Recognition Letters*, Vol. 32, No. 11, pp. 1584–1590, URL: <http://www.sciencedirect.com/science/article/pii/S0167865511001334>, DOI: <http://dx.doi.org/http://dx.doi.org/10.1016/j.patrec.2011.04.020>.
- [184] Yamamoto, K., Kimura, Y., Togami, T., Yoshioka, Y., Hashimoto, A., Kameoka, T., and Yoshitsugu, K. (2011) “A Chromatic Image Analysis System Using Content-Based Image Retrieval,” *Agricultural Information Research*, Vol. 20, No. 4, pp. 139–147, URL: <http://ci.nii.ac.jp/naid/130002104271/en/>, DOI: <http://dx.doi.org/10.3173/air.20.139>.
- [185] Yamamoto, K., Togami, T., Hashimoto, A., Yoshioka, Y., Ninomiya, S., and Kameoka, T. (2012a) “A Chromatic Image Analysis for Evaluating Appearance of Agricultural Products Using Color Distribution Entropy,” in *CIGR-Ageng2012*, Valencia, Spain.
- [186] Yamamoto, K., Ninomiya, S., Yoshioka, Y., Togami, T., Hashimoto, A., and Kameoka, T. (2012b) “Quality Evaluation and Cultivar Identification of Strawberry Using Image Analysis,” in *AFITA/WCCA2012*, Taipei, Taiwan.
- [187] Yamamoto, K., Kameoka, T., and Ninomiya, S. (2013) “Image Analysis System for the Evaluation of External Appearances of Agricultural Products,” in *The Third International Symposium on Biological Shape Analysis*, Tokyo, Japan.
- [188] Yamamoto, K., Ninomiya, S., Kimura, Y., Hashimoto, A., Yoshioka, Y., and Kameoka,

- T. (2015) "Strawberry cultivar identification and quality evaluation on the basis of multiple fruit appearance features," *Computers and Electronics in Agriculture*, Vol. 110, pp. 233–240, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914003019>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.11.018>.
- [189] Yamamoto, T., Nagasaki, H., Yonemaru, J.-i., Ebana, K., Nakajima, M., Shibaya, T., and Yano, M. (2010) "Fine definition of the pedigree haplotypes of closely related rice cultivars by means of genome-wide discovery of single-nucleotide polymorphisms," *BMC Genomics*, Vol. 11, No. 1, p. 267, URL: <http://www.biomedcentral.com/1471-2164/11/267>, DOI: <http://dx.doi.org/10.1186/1471-2164-11-267>.
- [190] Yamanaka, N., Ninomiya, S., Hoshi, M., Tsubokura, Y., Yano, M., Nagamura, Y., Sasaki, T., and Harada, K. (2001) "An informative linkage map of soybean reveals QTLs for flowering time, leaflet morphology and regions of segregation distortion," *DNA research*, Vol. 8, No. 2, pp. 61–72, URL: <http://dnaresearch.oxfordjournals.org/content/8/2/61.abstract>, DOI: <http://dx.doi.org/10.1093/dnares/8.2.61>.
- [191] Yan-zhu, Y., Xue-zeng, Z., Wei-jie, W., and Xian, W. (2002) "Review on the proceeding of automatic seedlings classification by computer vision," *Journal of Forestry Research*, Vol. 13, No. 3, pp. 245–249.
- [192] Yang, C., Lee, W. S., and Gader, P. (2014) "Hyperspectral band selection for detecting different blueberry fruit maturity stages," *Computers and Electronics in Agriculture*, Vol. 109, pp. 23–31, URL: <http://www.sciencedirect.com/science/article/pii/S0168169914002087>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.08.009>.
- [193] Yang, C., Odvody, G. N., Fernandez, C. J., Landivar, J. a., Minzenmayer, R. R., and Nichols, R. L. (2014) "Evaluating unsupervised and supervised image classification methods for mapping cotton root rot," *Precision Agriculture*, pp. 1–15, URL: <http://link.springer.com/10.1007/s11119-014-9370-9>, DOI: <http://dx.doi.org/10.1007/s11119-014-9370-9>.
- [194] Yang, W., Xu, X., Duan, L., Luo, Q., Chen, S., Zeng, S., and Liu, Q. (2011) "High-throughput measurement of rice tillers using a conveyor equipped with x-ray computed tomography," *The Review of scientific instruments*, Vol. 82, No. 2, URL: <http://www.ncbi.nlm.nih.gov/pubmed/21361628>, DOI: <http://dx.doi.org/10.1063/1.3531980>.

- [195] Yazdanbakhsh, N. and Fisahn, J. (2009) “High throughput phenotyping of root growth dynamics, lateral root formation, root architecture and root hair development enabled by PlaRoM,” *Functional Plant Biology*, Vol. 36, No. 11, pp. 938–946, URL: http://www.publish.csiro.au/view/journals/dsp_journal_fulltext.cfm?nid=102&f=FP09167, DOI: <http://dx.doi.org/10.1071/FP09167>.
- [196] Yin, H., Chai, Y., Yang, S. X., and Mittal, G. S. (2009) “Ripe Tomato Extraction For A Harvesting Robotic System,” in *Systems, Man and Cybernetics, 2009. SMC 2009. IEEE International Conference on*, pp. 2984–2989.
- [197] Yoshioka, Y., Iwata, H., Tabata, M., Ninomiya, S., and Ohsawa, R. (2007) “Chalkiness in Rice: Potential for Evaluation with Image Analysis,” *Crop Science*, Vol. 47, No. 5, pp. 2113–2120, URL: <https://dl.sciencesocieties.org/publications/cs/abstracts/47/5/2113>, DOI: <http://dx.doi.org/10.2135/cropsci2006.10.0631sc>.
- [198] Yoshioka, Y. and Fukino, N. (2009) “Image-based phenotyping: use of colour signature in evaluation of melon fruit colour,” *Euphytica*, Vol. 171, No. 3, pp. 409–416, URL: <http://www.springerlink.com/index/10.1007/s10681-009-0071-9>, DOI: <http://dx.doi.org/10.1007/s10681-009-0071-9>.
- [199] Zhang, B., Huang, W., Li, J., Zhao, C., Fan, S., Wu, J., and Liu, C. (2014) “Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review,” *Food Research International*, Vol. 62, pp. 326–343, DOI: <http://dx.doi.org/10.1016/j.foodres.2014.03.012>.
- [200] Zhang, J., Marszaek, M., Lazebnik, S., and Schmid, C. (2007) “Local features and kernels for classification of texture and object categories: A comprehensive study,” *International Journal of Computer Vision*, Vol. 73, No. 2, pp. 213–238.
- [201] Zhao, Y.-X., Wang, K.-R., Bai, Z.-Y., Li, S.-K., Xie, R.-Z., and Gao, S.-J. (2009) “Research of Maize Leaf Disease Identifying Models Based Image Recognition,” in Cao, W., White, J., and Wang, E. eds. *Crop Modeling and Decision Support*: Springer Berlin Heidelberg, pp. 317–324, URL: http://dx.doi.org/10.1007/978-3-642-01132-0_35, DOI: http://dx.doi.org/10.1007/978-3-642-01132-0_35.
- [202] Zhou, R., Damerow, L., Sun, Y., and Blanke, M. M. (2012) “Using colour features of cv. ‘Gala’ apple fruits in an orchard in image processing to predict yield,” *Precision Agri-*

- culture*, Vol. 13, No. 5, pp. 568–580, URL: <http://www.springerlink.com/index/10.1007/s11119-012-9269-2>, DOI: <http://dx.doi.org/10.1007/s11119-012-9269-2>.
- [203] Zhou, R., Kaneko, S., Tanaka, F., Kayamori, M., and Shimizu, M. (2014) “Disease detection of Cercospora Leaf Spot in sugar beet by robust template matching,” *Computers and Electronics in Agriculture*, Vol. 108, pp. 58–70, URL: <http://linkinghub.elsevier.com/retrieve/pii/S0168169914001768>, DOI: <http://dx.doi.org/10.1016/j.compag.2014.07.004>.
- [204] Zhou, X., Yu, K., Zhang, T., and Huang, T. S. (2010) “Image classification using super-vector coding of local image descriptors,” in *Computer Vision—ECCV 2010*, pp. 141–154.
- [205] 青木宏史 (1973) 「接ぎ木栽培の技術」, 『農業技術大系 野菜編 2 トマト』, 農山漁村文化協会, 361–374 頁.
- [206] 雨森道紘・横水伸行 (2005) 「果実そ菜類の等級の新しい自動画像解析判別法」, 『電気学会論文誌 C (電子・情報・システム部門誌)』, 第 125 巻, 第 9 号, 1476–1480 頁, DOI: <http://dx.doi.org/10.1541/ieejeiss.125.1476>.
- [207] 池田英男・川城英夫 (2005) 『野菜栽培の基礎 (農学基礎セミナー)』, 農山漁村文化協会.
- [208] 石岡恒憲 (2006) 「x-means 法改良の一提案—k-means 法の逐次繰り返しとクラスターの再併合—」, 『計算機統計学』, 第 18 巻, 第 1 号, 3–13 頁, URL: <http://ci.nii.ac.jp/naid/110004818389/>.
- [209] 大田登・森礼於 (2011) 「光と色」, 日本色彩学会 (編) 『色彩科学ハンドブック』, 東京大学出版会, 第 3 版, 13–15 頁.
- [210] 太田勝巳 (2013) 「トマトにおける脇芽発生と昼夜間の茎伸長との関係について」, Technical report, 島根大学生物資源科学部研究報告, 41–44 頁, URL: <http://ci.nii.ac.jp/naid/110009616665/>.
- [211] 香川県農政水産部農業経営課 (2014) 「かがわアグリネット」, URL: http://www.pref.kagawa.lg.jp/agrinet/dougubako/07/yasai/mini_tomato_7.htm (アクセス日: 2015-01-01).
- [212] 門田充司・近藤直・森本純 (2000) 「サツマイモ育苗作業自動化のための画像処理技術切断候補点の検出」, 『日本植物工場学会大会学術講演要旨集』, 124–125 頁, URL: <http://mama.agr.okayama-u.ac.jp/kenkyu/99/jun/jun.html>.
- [213] 亀岡孝治 (2014) 「果樹作のスマート化」, 農業情報学会 (編) 『スマート農業 - 農業・農村の

- イノベーションとサステナビリティ』, 農林統計出版, 106-127 頁.
- [214] 川村誠 (2002) 「色彩の印象に関する主観的評価モデル構築手法の提案」, 博士論文, 筑波大学.
- [215] 北村八祥・森利樹・橋本篤・亀岡孝治 (2005) 「画像解析を用いたイチゴ果実の品種特性評価法」, 『自動制御連合講演会講演論文集』, 第 48 巻, 277-277 頁, URL: <http://ci.nii.ac.jp/naid/130004599787/>, DOI: <http://dx.doi.org/10.11511/jacc.48.0.277.0>.
- [216] 栗田充隆・近藤直・吉丸寿一・二宮和則 (2006) 「トマトの等級判定のための色および形状特徴抽出方法」, 『植物環境工学』, 第 18 巻, 第 2 号, 145-153 頁, DOI: <http://dx.doi.org/10.2525/shita.18.145>.
- [217] 黒崎秀仁・大森弘美・高市益行・岩崎泰永 (2012) 「トマト低段密植栽培に対応した着果処理ロボットの開発 (第 1 報): 画像処理による開花部位の認識と噴霧機構の開発」, 『農業機械學會誌』, 第 74 巻, 第 6 号, 490-497 頁, URL: <http://ci.nii.ac.jp/naid/10031130954/>.
- [218] 古谷野恭代・全昶厚・古在豊樹 (2005) 「DIF の経日変化によるトマト実生の胚軸および各節間長の制御」, 『植物環境工学』, 第 17 巻, 第 2 号, 68-74 頁, DOI: <http://dx.doi.org/10.2525/shita.17.68>.
- [219] 佐々木栄裕・今野峻一・恒川佳隆 (2013) 「エッジ画像と色情報を用いた SURF アルゴリズムの検討」, 『計測自動制御学会』, 第 4 巻, 1-7 頁.
- [220] 澁澤栄 (2006) 『精密農業』, 朝倉書店.
- [221] 澁澤栄 (2010) 「第 5 世代の精密農業日本から発信するコミュニティベース精密農業」, Technical Report 256, 特許庁, 31-37 頁, URL: <http://www.tokugikon.jp/gikonshi/256/256tokusyu03.pdf>.
- [222] 総務省統計局 (2014) 「日本の統計 2014」, Technical report, 総務省, URL: <http://www.stat.go.jp/data/nihon/index2.htm>.
- [223] 田中和人 (1990) 「花きの高品質生産における諸問題-キクの品質と日持ちについて-」, Technical report, 石川県農業研究成果集報.
- [224] 永田雅輝・木下統・浅野克典・曹其新・日吉健二 (1996a) 「イチゴの自動選別システムに関する研究 (第 2 報): 画像処理による選別のための果形判別法」, 『農業機械學會誌』, 第 58 巻, 第 6 号, 61-67 頁, URL: <http://ci.nii.ac.jp/naid/10019120773/>.
- [225] 永田雅輝・木下統・浅野克典・曹其新・日吉健二 (1996b) 「イチゴの自動選別システムに関する研究 (第 1 報): 画像処理による果形の幾何学的特徴の抽出」, 『農業機械學會誌』, 第 58 巻, 第 5 号, 57-63 頁, URL: <http://ci.nii.ac.jp/naid/10019121012/>.

- [226] 永田雅輝・木下統・浅野克典・曹其新・日吉健二 (1997) 「イチゴの自動選別システムに関する研究 (第3報): 画像処理による自動選別システムの開発」, 『農業機械學會誌』, 第59巻, 第1号, 43-48頁, URL: <http://ci.nii.ac.jp/naid/10019120543/>.
- [227] 新潟県経営普及課・農産園芸課 (2003) 『野菜栽培指針』, 新潟県農林水産部農産園芸課, URL: http://www.maff.go.jp/j/seisan/kankyo/hozen_type/h_sehi_kizyun/nii04.html.
- [228] 二宮正士 (2014) 「フィールドフェノミクス」, 農業情報学会 (編) 『スマート農業 - 農業・農村のイノベーションとサステナビリティ』, 農林統計出版, 55-57頁.
- [229] 農林水産省 (2011) 「農林水産省品種登録ホームページ」, URL: <http://www.hinsyu.maff.go.jp/top.html> (アクセス日: 2015-03-01).
- [230] 農林水産省 (2014) 「農林水産植物種類別審査基準」, URL: http://www.hinsyu.maff.go.jp/info/sinsakijun/botanical_taxon.html (アクセス日: 2015-03-01).
- [231] 農林水産術会議 (2008) 「日本型精密農業を目指した技術開発」, Technical report, 農林水産省, URL: <http://www.s.affrc.go.jp/docs/report/report.htm>.
- [232] 福田邦夫 (1991) 「色票と色票系」, 日本色彩学会 (編) 『色彩科学辞典』, 朝倉書店, 第1版, 144頁.
- [233] 福田直子・大澤良・吉岡洋輔・中山真義 (2005) 「トルコギキョウにおける覆輪安定性の数値化による品種間変異の評価」, 『園芸学研究』, 第4巻, 第3号, 265-269頁, URL: <http://ci.nii.ac.jp/naid/110001828156/>.
- [234] 元永佳孝 (2000) 「農産物の外観特性の定量化に関する基礎的研究」, 博士論文, 三重大学.
- [235] 安井公一・大島昭夫・松浦次郎 (1985) 「電照ギク栽培における摘心後の栄養生長期間と切花長」, Technical report, 岡山大学農学部, 20-23頁.
- [236] 柳井啓司 (2007) 「一般物体認識の現状と今後」, 『情報処理学会論文誌』, 第48巻, 1-24頁.
- [237] 山本恭輔・木村佳嗣・戸上崇・吉岡洋輔・橋本篤・亀岡孝治 (2011) 「CBIR手法を用いた色彩画像解析システムの構築」, 『農業情報研究』, 第20巻, 第4号, 139-147頁, URL: <http://ci.nii.ac.jp/naid/130002104271/>, DOI: <http://dx.doi.org/10.3173/air.20.139>.