

無人航空機（UAV）と人工知能（AI）を用
いたバレイショの収量予測に関する研究

岩手大学連合農学研究科

田邊 大

目次

第I章	序言	1
第1節	研究の背景	1
第2節	研究の経緯	5
第3節	研究の目的	10
第4節	論文の構成	11
第II章	UAV とマルチスペクトルカメラを用いたモニタリングシステムの開発	13
第1節	緒言	13
第2節	材料と方法	16
第3節	実験結果と考察	25
	(1) 画像合成と空撮画像からの判読	25
	(2) NDVI と SPAD の関係	26
	(3) 収量調査結果と NDVI との相関関係	27
第4節	摘要	28
第III章	CNN を用いた画像の分類によるバレイショ収量予測システムの開発	58
第1節	緒言	58
第2節	材料と方法	59
第3節	実験結果と考察	64
	(1) 空撮画像によるバレイショの生育状況	64
	(2) 各試験区におけるバレイショの生育	65
	(3) 各試験区におけるバレイショの収量	67
	(4) 収量、NDVI、草丈についての重回帰分析	68
	(5) 画像分類 CNN モデルによる収量予測精度	69
第4節	摘要	71

第IV章	CNNを用いた画像の回帰によるバレイショの収量予測システムの開発	91
第1節	緒言	91
第2節	材料と方法	92
第3節	実験結果と考察	97
	(1) 空撮画像によるバレイショの生育状況	97
	(2) 各試験区におけるバレイショの生育	99
	(3) 各試験区におけるバレイショの収量	99
	(4) 回帰分析	101
	(5) 画像回帰CNNモデルによる収量予測	103
第4節	摘要	105
第V章	総合考察	130
第1節	モニタリングシステムの選定	130
第2節	各種CNN技術とFine tuning技術の露地畑作栽培での有用性	154
第3節	収量予測システムの実装と他作目への展開	165
第VI章	結論	176
	謝辞	180
	参考文献	181

第 I 章 序言

第 1 節 研究の背景

現在，我が国では，農業従事者の高齢化による担い手の減少や耕作放棄地の増加が問題となっている。本学のある山形県も例外ではなく，農家戸数が平成 22 年から平成 27 年の間で 1,631,206 戸から 1,329,591 戸と大きく減少し，60 歳以上の農業従事者が男女合わせて 41,059 人で全体の約 76.5%，耕作放棄地が 8,372 ha に及んでいる¹⁾。山形県では中山間地域での耕作放棄地が顕著であることから，それに対して様々な取り組みが行われている²⁾。一例として，山形県の沿岸部にある鶴岡市では水稻や畑作物などの土地利用型作物の生産を行う農業生産法人の支援に加え，耕作放棄地化した山間部の放牧地や牧草地の整備，エダマメや赤かぶ，ニンジンなど園芸作物の生産振興を図っている。また，農業従事者の高齢化や減少は篤農技術の途絶を引き起こすため，若い人材の育成や技術の継承が必要となっている。これには農水省で行われている「スマート農業技術の開発・実証プロジェクト」³⁾などによる農業の ICT 化技術を活用し，農業技術のノウハウをデータベース化して対応することが進められている。

山形県において畑作物であるバレイショやダイズは作付面積，10 a 当たりの収量がいずれも減少傾向にある。バレイショの作付面積と単位面積当たり

収量は、2007年から2016年の間で289 haから212 ha、2000 kg/10aから1750 kg/10aに減少し、ダイズは7040 haから5150 ha、149 kg/10aから133 kg/10aに減少している。また、コムギは同期間に作付け面積が110 haから87 haと減少傾向で、収量は日本海側の気象条件によって151～284 kg/10aの間と年次変動が大きく、太平洋側の地域と比較して低水準になっている⁴⁾。地域の農業生産を活性化するには、作付け面積と単位面積当たりの収量向上が重要である。それに対し、松尾は中山間地域などの傾斜地でバレイショなどの畑作物を積極的に栽培し、収穫した畑作物を地域内で循環する社会「スマート・テロワール」を提唱しており⁵⁾、長野県や山形県庄内地域をモデルとして畑輪作体系の実証試験が行われている⁶⁾。

「スマート・テロワール」とは、「賢い」、「利口な」、「洗練された」といった意味の「スマート」と、地域独自の風土、景観、品種、栽培法などが育む「特徴ある地域」を意味するフランス語の「テロワール」を組み合わせた造語である。これは我が国における農村部に6次産業化をベースとした自給圏を構築し、農村部の経済的な発展や地域振興を達成しようという概念である。

「スマート・テロワール」構想はいくつかのステップによって構成される。①余剰水田や耕作放棄地

を畑に転換し，バレイショやダイズ，コムギといった畑作物を生産する。②収穫した畑作物は地域内の食品加工業者に提供し，加工食品の生産を行う。③規格外収穫物は畜産業者に提供し，飼料として利用する。そこで生産された畜肉は畑作物と同様に，地域内の食品加工業者が加工する。④畜産業から発生した糞尿などは，堆肥などの形で畑へ還元する。「スマート・テロワール」構想は，これらのサイクルを地域レベルで行うことで，物質，経済の循環を可能にし，農業の6次産業化を地域レベルで展開することで雇用創出と活性化を同時に達成することを目的としている。

農業の6次産業化は今村が提唱した概念で1次産業である農業，2次産業である製造業，3次産業である流通・小売業を総合的に結合させるものである⁷⁾。これには，農作物の生産や加工，食料品の製造にあたり可能な限り生産性を高め，コストの低減と収益の確保をはかる必要がある。農業で生産性や収益を向上させるには，より高い精度で省力的な収量予測システムを確立し，農作物をマネジメントすることが必要になる。

他方，近年ICTなどの情報技術を高度に活用したデータに基づく農業が注目されており，それにロボット化や人工知能技術を利用したスマート農業の取り組みが進められている⁸⁾。効率的に情報を収集

する方法としては，人工衛星や航空機を用いたリモートセンシング技術があり，水稻を中心とした多くの土地利用型作物で利用されている。脇山らは，水稻登熟期における衛星データとアメダスデータから水稻の収量予測モデルを構築し，高い精度で収量を予測できることを示した⁹⁾。また，境谷らは航空機に搭載したハイパースペクトルセンサーで青森県津軽中央地域の水田を複数年観測し，リモートセンシングによる玄米タンパク含有率の推定とそれに影響する誤差要因を明らかにしている¹⁰⁾。しかし，上記のようなセンシング機器では撮影時の気象やタイミングに制限があるため，機動性に優れたプラットフォームとして無人航空機（Unmanned Aerial Vehicle, UAV）の利用が進んできている¹¹⁾。濱らはUAVリモートセンシングと登熟期の気温を用いることで，多年次，他地域に適用可能な玄米タンパク推定モデルを構築している¹²⁾。また，山本らは，UAVリモートセンシングによるダイズの湿害評価を試みている¹³⁾。

リモートセンシングを始めとした農業のICT化では，そこで得られるビッグデータを解析する技術として，人工知能（Artificial Intelligence, AI）が注目されている。これは人間の脳神経を模したニューラルネットワークから成り，特にこれを多層に積み重ねた深層学習の登場によってAI技術は飛躍的な発

展を遂げている¹⁴⁾。この AI 技術の農業分野への応用については、ほ場レベルでの作物種の分類や作物の病害検出に利用されている^{15) 16)}。しかし、AI の精度を高めるには多くの学習用データ（教師データ）が不可欠であるため、屋外で変動要因が多い土地利用型作物の収量予測に適用した事例が少ない。

第 2 節 研究の経緯

我が国におけるリモートセンシング技術を用いた農作物の収量や収穫物の特性を予測する事例は、主に水稲やコムギを中心として多数報告されている。また、それらで利用しているプラットフォームは人工衛星や航空機、UAV と多岐に渡る。

人工衛星の利用に関し、串田らは地上測定による水稲スペクトル情報の時系列ごとの輝度値の補正手法を考案し、それを実際のランドサット TM データに適用することで、スペクトルデータと水稲の単位面積当たり収量の関係を調査している。その結果、考案した手法は、輝度値をそのまま用いる手法と比較して水稲の単位面積当たり収量を示す指標として有効であることが報告されている¹⁷⁾。池田らは IKONOS 衛星画像データによるコムギの収量予測を検討しており、幼穂形成期の衛星画像から算出された NDVI とコムギの地上部風乾重および収量との相関が見られ、当該期間の画像からほ場ごとのコムギ

収量を予測できることを示した¹⁸⁾。コムギは幼穂形成以降窒素吸収量が増大し、それと同調するように乾物生産量も増大することが知られており、前述の事例は NDVI と窒素吸収量との相関を応用したものである¹⁹⁾、²⁰⁾。安積らは SPOT 衛星や Quick Bird 衛星、Terra/ASTER 衛星で得られたデータを基に秋まきコムギの子実タンパク含有率を推定し、その地理的変動を地図化する手法を検討している。それによると収穫期の 3～4 週間前以降に取得した衛星画像はコムギの子実タンパク含有率を推定することが可能で、そこから作成した子実タンパク含有率区分図を用いることで、広域での子実タンパク含有率の変動を把握できる。その結果は、土壌や地形などに対応した施肥管理など地域全体での管理に役立てられることを示している²¹⁾。秋元らはランドサット MSS データで草地を診断し、1 番草の収量を推定している。牧草収量は、草地にクラス分けされた諸地点のランドサット MSS の各バンドのスペクトルデータを説明変数、牧草乾物収量を目的変数とする重回帰モデルを利用することで高い精度で予測可能であることを示している²²⁾。

航空機リモートセンシングに関し、井上らは航空機計測によるハイパースペクトルデータの任意の 2 波長から算出する正規化分光反射指数と PLS 回帰法を用いて、登熟期における米粒タンパク含有率、ク

ロロフィル濃度，バイオマスの予測を試みており，それぞれに適したスペクトルデータの抽出と精度の良好な予測モデルの構築を行っている²³⁾。また，小田川らは航空機ハイパースペクトルデータを用いて，水稻の生育，収量，タンパク含有率をLasso回帰によって推定する手法を検討している。その結果，移動平均によってノイズを低減したハイパースペクトルデータから最適なバンドを選択し，Lasso回帰を適用する手法は，水稻の生育初期から後期にかけて収量，タンパク含有率，LAI(葉面積指数)，SPAD値および莖数に対して有効な回帰モデルを作成できることを報告している²⁴⁾。また，中坪らは航空機リモートセンシングによるハイパースペクトルデータを用いて飼料用トウモロコシの収量と飼料成分含有率の推定を行っており，スペクトルデータに一次微分処理およびバンド選択を行うことで，乳熟期のハイパースペクトルから収穫期のトウモロコシ子実収量，粗タンパク質，総繊維および灰分を推定できることを示している²⁵⁾。

そして近年リモートセンシングのプラットフォームとしてUAVが新たに登場しており，それを利用したリモートセンシングによる作物の生育や収量を予測した事例も盛んに報告されている。濱らはUAVリモートセンシングによって得られた水稻の植生指数データ(水域や土壌を除いたNDVIとGNDVI)

を説明変数とした回帰モデルによって水稻の草丈を高い精度で予測するモデルを提案している²⁶⁾。また、同氏は UAV リモートセンシングデータと登熟期の気象データを基に水稻の玄米タンパク含有率の推定を検討しており、NDVI データと登熟期の気温データを説明変数とした重回帰分析が NDVI を説明変数とした単回帰よりも高い精度で玄米タンパクを予測できることを示している¹²⁾。さらに、田中らは UAV とマルチスペクトルカメラを用いたリモートセンシングと複数の機械学習手法を組み合わせることで小麦の収量および子実タンパク質含有率を推定している。その結果、収量の推定は EVI2 (Enhanced Vegetation Index 2, 強化型植生指数 2) を説明変数とした回帰分析が高い精度で予測可能であり、子実タンパク質は各波長の反射率を予測変数としたランダムフォレストモデルが高い精度で予測できることを示している²⁷⁾。

ここまでの、水稻を中心にリモートセンシング情報を基にした収量、成分を予測した事例に触れてきたが、畑作物であるバレイショの事例もいくつか存在する。横堀らは無人ヘリコプターを用いてバレイショ (トヨシロ) 生育のばらつきを解析しており、リモートセンシングデータから土壌表層腐食含量、バレイショの生育量 (SPAD×草丈) を推定し、これらの情報を基に適切に管理することで、収量不足や窒

素過剰による品質低下を抑制できることを示している²⁸⁾。また、辻らは UAV を用いて算出した植被率を基に推定した受光日射量と収量との関係を調査しており、全イモ重が黄変期以降の積算受光量と相関が高いことを示している²⁹⁾。さらに、Gómezらはセンチネル 2 衛星画像といくつかの機械学習手法を組み合わせたバレイショの収量予測モデルの構築を行い、7月と8月の衛星画像データとサポートベクタマシンとランダムフォレストモデルによって高い精度で収量を予測できることを報告している³⁰⁾。

上記の事例は研究段階のものであるが、実用レベルで農作物の収量予測などを行っている事例も存在する。ズコーシャ(株)は精密農業に関する事業として精密農業支援システムによるコンサルタント事業を展開している³¹⁾。既存の GIS データ、土壌・作物データと人工衛星データ、気象データおよびそれらを基に構築した各種予測モデル(土壌水分予測、病虫害予測、作物収量予測)から、土壌情報や作物情報に関するほ場マップを作成し、そのばらつきに対応した最適なほ場管理を行うための意思決定を補助するシステムを展開している。農家や JA は、このシステムによってほ場ごとの土壌情報、作物情報、管理計画等を取得することが可能となる。また、行政は土壌情報を利用することで、暗渠工事

などの土地改良事業を効果的かつ戦略的に行うことができる。また、DATAFLUCT（株）は、生産現場の人工衛星モニタリングや気象データ、市場取引価格の AI 予測で国産野菜の安定供給をサポートする「DATAFLUCT agri.」を 2020 年 2 月からスタートさせている³²⁾。これは国産野菜を契約農家から仕入れている食品加工産業や外食産業をメインターゲットとしており、人工衛星モニタリングで遠隔地から契約農家ほ場の生産状況（収量、収穫時期等）を把握し、過去の市場取引価格および気象データを用いた AI による市場価格の予測とを組み合わせ、仕入れコストの削減につなげるというものである。

以上のように、リモートセンシングによる水稻をはじめとした農作物の収量あるいは成分を予測する事例は数多く報告されており、バレイショを対象とした事例でも国内外で研究されているが、リモートセンシングデータと CNN 技術を組み合わせた新たな生育・収量の予測手法は報告されていない。

第 3 節 研究の目的

本研究では農業分野での ICT 化による次世代農業を確立し、生産技術の継承と担い手の育成による地域の活性化を目的に、UAV をセンシングデバイスとして得られた空撮画像データを活用し、それを AI による深層学習で解析する新たなモニタリングシス

テムの開発を行った。開発したモニタリングシステムは山形県庄内地域で行われている中山間地域を活用した畑輪作体系でのバレイショ栽培に適用し、UAVを用いたバレイショの生育情報の収集、生育に関する画像情報を基に畳み込みニューラルネットワーク（CNN）による画像の分類手法を応用した収量予測手法の確立と精度評価を行った。また、収量の予測精度を向上するため、Fine tuning および CNN による画像の回帰手法についても検討し、生産現場で利用可能な普遍的手法の構築を行った。

第 4 節 論文の構成

本論文は第 I 章の序言から始まり、UAV とマルチスペクトルカメラを組み合わせたバレイショほ場のモニタリングシステムの開発から、CNN を用いたバレイショの収量予測システムの開発について検討した全 6 章で構成されている。第 II 章では主に UAV とマルチスペクトルカメラを組み合わせたモニタリングシステムの開発について検討し、空撮画像の画像合成および空撮画像からの判読、NDVI と SPAD の関係、そしてバレイショ収量調査結果と NDVI との相関関係を考察している。第 III 章では CNN を用いた画像の分類によるバレイショの収量予測システムの開発とその精度について評価する。第 IV 章では CNN を用いた画像の回帰によるバレイショ

の収量予測システムの開発とその精度について検討する。第 V 章は総合考察として，モニタリングシステムの選定，各種 CNN 技術と Fine tuning 技術の露地畑作物栽培での有用性，収量予測システムの実装と多作目への展開について検討する。そして第 VI 章では，本研究で得られた結論を列挙し，UAV を利用したバレイショの収量予測に関する研究をまとめ，本稿を終了する。

第 II 章 UAV とマルチスペクトルカメラを用いた モニタリングシステムの開発

第 1 節 緒言

現在我が国では，農業従事者数の高齢化や減少，耕作放棄地の増加が問題となっている。特に山形県は中山間地域において耕作放棄地の増加が著しい。それらの諸問題に対しては，ICT 技術を活用したスマート農業が有効である。このスマート農業では，ほ場内の情報を効率的に収集する方法として人工衛星や航空機を用いたリモートセンシング技術があり，水稻を中心とした多くの土地利用型作物で利用されている。脇山らは，水稻登熟期における衛星データとアメダスデータから水稻の収量予測モデルを構築し，高い精度で収量を予測できることを示した⁹⁾。また，境谷らは航空機に搭載したハイパースペクトルセンサで青森県津軽中央地域の水田を複数年観測し，リモートセンシングによる玄米タンパク含有率の推定とそれに影響する誤差要因を明らかにしている¹⁰⁾。しかし，上記のようなセンシング機器では撮影時の気象やタイミングに制限があるため，機動性に優れたプラットフォームとして UAV の利用が進んできている¹¹⁾。濱らは UAV リモートセンシングと登熟期の気温を用いることで，他地域に適用可能な玄米タンパク推定モデルを構築している¹²⁾。また，山本らは，UAV リモートセンシ

ングによるダイズの湿害評価を試みている¹³⁾。

リモートセンシングでは，センサから得られた分光放射データから植生量を示すため，現在まで様々な指標が開発されている。基本的な植生指数は，赤色域と近赤外域における植生，土壌のスペクトルの反射応答の違いを利用して算出されており，放射照度の違いや大気透過に伴う変動等の要因に対する感受性を最小化できる。その中でも多くの事例で使用されている植生指数には，正規化差分植生指数（Normalized Difference Vegetation Index, NDVI）がある。これは赤色域，近赤外域の放射輝度あるいは反射率の差分をそれらの合計で割ったもので，次式で算出される。

$$NDVI = \frac{\rho_{NIR} - \rho_{Red}}{\rho_{NIR} + \rho_{Red}}$$

ここで， ρ_{NIR} ， ρ_{Red} はそれぞれ近赤外域，赤色域の反射率を表す。

NDVIは一般的に-1から1の値をとる特徴を持ち，群落密度やその光合成活性といった変数と正の相関があるとされている（ただし，雲，雪面，水面では $\rho_{Red} > \rho_{NIR}$ となり，負の値を示す）。また，NDVIは放射条件の違いや日照条件の違いなどを正規化して比較しやすくし，反射率や放射輝度どちらにも適用ができることから，多くのリモートセンシング事例で一般的に利用されている³³⁾。

NDVIは農業分野においても広く利用されている。水稲では、携帯型分光放射センサを用いてNDVIを算出し、稲体窒素吸収量との関係を調査した事例が報告されている。これによると生育期間中の水稲の窒素吸収量とNDVI値には指数関数的な相関関係があり、生育ステージ別での検量線作成と毎年のキャリブレーションを行うことで、NDVIから水稲窒素吸収量の推定が可能とされている³⁴⁾。コムギでは、人工衛星リモートセンシングで得られたNDVIデータと子実タンパク質の関係を調査した事例が報告されており、NDVIと子実タンパク質の相関は成熟期に近づくにつれ高くなり、これらの変数を基にした回帰式を衛星画像のコムギほ場の全画素に適用することで、衛星データからコムギの子実タンパク含有率を推定し、地図化することが可能である³⁵⁾。また、濱らはUAVと近赤外撮影用カメラを組み合わせたセンシングシステムを用いて、水稲の出穂期におけるNDVIが最も玄米タンパク質と相関が高く、登熟期の平均気温データと併せて説明変数とすることで、より高い精度で玄米タンパク質を予測できることを示している¹²⁾。

モニタリングシステムのプラットフォームであるUAVは、対象作物や用途、搭載するセンサに合わせて構築することが必要となる。

本試験ではセンサは作物の窒素吸収量を評価す

るために、近赤外域光を捉えることができるマルチスペクトルカメラを選定した。UAVはマルチスペクトルカメラを搭載するのに十分なペイロードを持つ UAVとして大型の産業用空撮マルチコプター（DJI社，S900）を選定した。本研究ではこれらを組み合わせたモニタリングシステムを開発し、実際にバレイショ栽培に導入してその実用性を評価した。

第2節 材料と方法

(1) 試験ほ場

実験は山形県鶴岡市に位置する山形大学農学部附属やまがたフィールド科学センター（高坂農場）内のほ場（長辺：40 m，短辺：20 m，面積：8 a）で行った（図2-1）。試験ほ場は2017年4月21日に粗耕起した後，4月25日に施肥と耕うんを行い，芽出したバレイショを畝間0.75 m，株間0.30 mの条件で定植した。供試作物は庄内地域の畑輪作体系における中山間地域での栽培を想定して，バレイショ（トヨシロ）を用いた。基肥は高度化成肥料（14：14：14）を10 g-N/m²，追肥は硫安を4.2 g-N/m²施用した。バレイショの開花前に収量調査用の調査プロットを作成した。

(2) 実験機の構成と撮影条件

ほ場の空撮は空撮用マルチコプター（DJI社，S900）

にマルチスペクトルカメラ（Tetracam 社，MicroMCA/RGB+3）を取り付けて行った（図 2-2，2-3）。

供試した UAV は基盤が内蔵されたフレーム部，ESC（Electric Speed Controller）やモーターが搭載されたアーム部，カメラジンバルやスキッドが搭載されるボトム部で構成した。フレーム部には 3 軸加速度センサやジャイロセンサ，気圧計などが内蔵されたフライトコントローラー，GPS，映像伝送装置（DJI 社，LightBridge2）などが搭載されている（図 2-4）。中でもフライトコントローラーは，機体の姿勢や飛行環境に合わせて各モーターの回転速度を制御するので，従来のシングルローターヘリと比較してより安定した飛行が可能である。折り畳みが可能なアーム部の先端には，ESC が一体型となったブラシレスモーターが搭載されている（図 2-5）。また，機体下部には前述のカメラジンバルを搭載した（図 2-6）。ジンバルは Pitch 方向を地上局側から任意の角度に調整できるようにし，空撮の際にはカメラが鉛直方向を向くようにして撮影を行った。また，機体下部には離着陸用の折り畳みが可能なスキッドが搭載されているが，本研究では墜落時にマルチスペクトルカメラおよびジンバルを保護する目的から非可動状態で運用した。

UAV の主要諸元を表 2-1 に示す。UAV の機体寸法

は全長，全幅が 900 mm，全高が 640 mm となっている。ペイロードは 8.2 kg となっている。搭載したカメラジンバルは IMU（慣性計測装置）とフライトコントローラーからの情報を基に 3 つのブラシレスモーターを制御することで振動を抑え，カメラを任意の角度に保つことができる。

供試センサは 4 つのレンズを搭載しており，それぞれ 570–700 nm（Red），480–550 nm（Green），400–470 nm（Blue）を取得できる 3 バンドカラーセンサと 680 nm（NDVI Red），720 nm（Red edge），800 nm（NIR）を取得可能なモノクロセンサを組み合わせた構成となっている³⁶⁾。

マルチスペクトルカメラの主要諸元を表 2-2 に示す。センサの解像度は 1280×1024 で，視野角は 35.7° × 28.9° × 44.8° となっている。カメラの質量は 400 g である。カメラにはジンバル取付用のネジ穴などがなかったため，ジンバルに取り付けるにあたって専用のカバーと留め具を 3DCAD および 3D プリンタを使用して作成した。

上記のセンサは UAV プラットフォームでの撮影に適した小型軽量のマルチスペクトルカメラで，重量，寸法が一般的なミラーレス一眼レフと同程度であるため，カメラを固定，保持するジンバルは，同等のカメラに対応したものが望ましい。そこで，カメラジンバルは産業用の空撮用ジンバル（DJI，

ZENMUSE Z15-A7)³⁷⁾を使用した。これはミラーレス一眼レフ (Sony, α7) 向けの大型カメラジンバルで、3つのブラシレスモーターから構成され、Yaw, Pitch, Roll 方向の3軸でセンサの動きを制御し、水平を保ちブレを抑えることができる。センサおよびジンバルの質量は合計約 1700 g なので、搭載する UAV にはペイロードにゆとりのある大型産業用マルチコプターを使用した。本機はヘキサコプター (6ローター) に該当するマルチコプターで、一般的なクアドコプター (4ローター) よりもペイロードが大きく、ローター数も多いことから、飛行中にモータートラブルが発生した場合にも最低限の揚力を確保できるためクアドコプターよりも安定性が高い。さらにローターの多いオクトコプターも存在するが、ヘキサコプターよりも安定性、ペイロードに優れる反面、機体が大きくなりすぎる、飛行時間が短いといった欠点を持ち、搭載するセンサ、およびジンバルの質量からも過剰なスペックであると判断し、本機を採用した。

空撮はバレイショ萌芽期の 2017 年 5 月 29 日、開花期の 6 月 6 日、20 日、黄化期である 7 月 13 日、20 日、27 日にそれぞれ行った。空撮は南中高度が高い 10:00~14:00 の間に行った。撮影高度は約 80 m でほ場中央部分から上昇させることでほ場全面が入るように撮影を行った。シャッターはカメラに搭

載されているタイムラプス機能を用いて 2 秒間隔で画像を取得した。

(3) 画像解析手法

前述のとおり供試センサは 4 つのレンズを搭載しており，それぞれ取得できるバンドが違う。また，各レンズの位置が違うため，視差を補正して 1 つの画像に合成する必要がある。この画像処理には PixelWrench2 (Tetracam) を使用した。

画像処理のフローチャートを図 2-7 に示す。画像合成の流れは以下のとおりである。

① 画像の取り込み

マルチスペクトルカメラを PC に接続し，カメラの電源を入れる。その後，MASTER (RGB 可視光バンド)，SLAVE1 (680 nm)，SLAVE2 (720 nm)，SLAVE3 (800 nm) の 4 つのセンサで撮影された画像をそれぞれ同一のフォルダに移動する。

② 各センサの視差補正に関する設定

PixelWrench2 を起動し (図 2-8)，取り込んだ画像を合成していく。4 つの異なるセンサで撮影された画像は視差が発生するため補正を行う。この際基準となるセンサは MASTER のセンサで，これに合わせて他の 3 つのセンサの視差を補正する。視差を補正するには「センサから撮影対象までの距離」が必要であるが，本試験では UAV での撮影高度を使用した。PixelWrench2 内の「View」のタブを開き，「FOV

Optical Calculator」をクリックする（図 2-9）。すると、「FOV Calculator」ウインドウが出るので、「Sensor type」を「MCA SNAP < 6.18,4.95,4.8」を選択し、「Object Distance」で撮影対象までの距離を入力する（図 2-10）。なお、このとき撮影対象までの距離が 100m 以上なら視差を無視できる。

③ 6 バンドの合成

視差補正の設定の次は取り込んだ画像を一つの画像（Multipage TIFF）に合成する。本試験で使ったマルチスペクトルカメラは Red, Green, Blue の可視光バンドおよび 680 nm, 720 nm, 800 nm の狭帯域光バンドの計 6 バンドを捕捉することができるが、これらのセンサでとらえたデータは放射輝度に変換する必要がある。まず Pixel Wrench2 内の「View」タブをクリックし、その中の「Index Tools」をクリックし、Index Tools ウインドウを出す（図 2-11）。次に MCA タブを開き、図 2-11 中の青枠の「Multipage Tifs」をクリックするとフォルダを参照するウインドウが出るので、マルチスペクトルカメラで撮影した TIFF 画像が収まっているフォルダを選択して OK をクリックする。このとき、フォルダの中には MASTER, Slave 1, 2, 3 の画像データが入っている必要がある。視差を補正する場合は図 2-11 中の下線部の「Align to FOV distance value」にチェックを入れる。その後、合成した画像を収めるフォルダを

選択して OK をクリックする。

④ 3 バンドカラー画像の構築

Multipage TIFF 画像は独自規格の画像のため、標準的な画像処理ソフトで使用するには一般的な画像形式に変換する必要がある。そこで、格納された 6 バンドのうち、任意の 3 バンドを選択して疑似カラー画像を合成した。本研究では 680 nm, 720 nm, Green の 3 バンドを選択し、疑似カラー画像を構築した。③ で作成した Multipage TIFF を「File」から表示する。次に任意の 3 チャンネルを選択して RGB に割り当てたカラー画像を作成する「Index Tools」を起動し、図 2-12 中の赤枠部分で RGB にそれぞれ任意のバンドを割り当てる。本試験の場合は、R に 680nm, G に 720nm, B に GREEN をそれぞれ割り当て、「MultiFrame Tif > RGB」をクリックする。なお、NDVI 値の算出や解析はここで構築した 3 バンドの疑似カラー画像中の植物が写ったピクセルのデータを抽出して使用した。

⑤ NDVI 空撮画像の作成

Pixel Wrench2 は疑似カラー画像の輝度値を基に NDVI などをはじめとした植生指数を算出し、それに基づいて最大で 17 クラスに色分けした画像を作成できる。適用するカラースケールは自由に作成、保存することができ、一度作成したカラースケールファイルを読み出して使用することができる。

「Index Tools」ウインドウの「Palette」タブをクリック（図 2-13）し，次いでカラーテーブルをクリックして 17 段階の色を指定する。作成したカラーテーブルは「Save Palette」をクリックして icp ファイルとして保存できる。NDVI カラー画像を作成する際にカラースケールを適用する場合は図 6 中の「Apply Palette」にチェックを入れる。NDVI 画像の横にカラースケールを入れる場合は「Apply Legend」にチェックを入れる。なお，「Scale Palette」はチェックを入れると画像の最大値，最小値を指定して 17 分割することができる。カラースケールの設定後，「Index」ウインドウの「Index」タブを開き，算出したい植生指数を選択し（図 2-14）で「Execute」ボタンをクリック（図 2-15）すると植生指数が算出され，マッピングした画像を作成することができる。

本試験において，植生指数は NDVI を使用した。NDVI は以下の式で算出した。

$$NDVI = \frac{DN_{720\text{ nm}} - DN_{680\text{ nm}}}{DN_{720\text{ nm}} + DN_{680\text{ nm}}}$$

ここで，DN 値は画像のピクセルごとの輝度値を表しており， $DN_{720\text{ nm}}$ ， $DN_{680\text{ nm}}$ はそれぞれ 720 nm，680 nm の輝度値を示す。

前述のとおり NDVI は，-1 から 1 の値をとり，植物群落の密度や光合成活性と相関があるとされ，日射条件の違いなどを正規化でき，反射率と放射輝度

のどちらにも適用可能であることから，多くの事例で利用されている。本研究でも上記の理由から，マルチスペクトルデータによる植生の定量化に NDVI を使用した。

本試験では植生の光合成活性を視覚的に判断するために NDVI をマッピングした NDVI 空撮画像を作成した。また，ラスタ演算を行う前のカラー画像中の植物体のピクセルの DN 値をそれぞれ抽出し，その値から NDVI 値を算出した。算出した NDVI 値と SPAD や収量データとの相関を調査した。NDVI 値の各プロットにおける多重比較には Tukey-Kramer 検定を利用した。統計ソフトは R (ver. 3.5.1) を使用した。

(4) 生育調査

生育調査は 2017 年 6 月 6 日，20 日，7 月 20 日，27 日に行った。調査項目は SPAD 値である。SPAD 値は葉緑素計 (SPAD502-plus, コニカミノルタ) で計測した。計測は，各調査プロットから 5 個体選定し，個体ごとに 5 回計測を行って平均化したものを個体ごとの SPAD 値とした。

(5) 収量調査

収量調査は 2017 年 8 月 1 日に行った。収量調査は各調査プロット内の連続 5 個体を掘り取って調査した。調査項目は塊茎重量 (g) で規格内品，規格外品それぞれ計測し，株あたり塊茎重量と 10a 当たり

株数の積から収量（kg/10a）を求めた。規格外品の項目は腐敗（軟腐病）、緑化、傷、変形、食害、内部障害、その他である。

第 3 節 実験結果と考察

(1) 画像合成と空撮画像からの判読

図 2-16 に試験ほ場の各時期の RGB 空撮画像，図 2-17 に試験ほ場の各時期の NDVI 画像，図 2-18 に地上部の様子を示す。NDVI 画像におけるカラースケールは図中の右側である。空撮画像の分解能は約 3.6 cm/pixel であった。

萌芽期に当たる 5 月 29 日の画像から，バレイショの萌芽の進行が確認できる。萌芽の進行にばらつきがあるが，これは定植時の種イモの状態の違いによって引き起こされた。一般的にバレイショ栽培では，定植前の種イモは浴光催芽を行い，芽を徒長させないで成長させ，植え付けから萌芽までの時間を短縮し，萌芽後の初期成育を促進させることができる。また，定植する種イモは切断して一片 40 g 程度に調整するが，40 g 以下の場合には種イモ片の大きさに比例して初期成育が促進されて収量が増加し，40 g 以上の場合はその傾向が緩やかになるとされている³⁸⁾。

次に生育期間である 6 月 6 日，6 月 20 日の画像では次第に NDVI が高くなり，植被が増大しているこ

とがわかる。開花期である 6 月 20 日の NDVI 画像では、赤い植生部分に白い光合成活性の低い点が確認できる。これは光合成活性の低い花卉が写り込んだものであり、地上部の様子とも合致する。黄化期である 7 月 13 日から 20 日、27 日の画像では、植物体が黄化していったため植被が減少した。7 月 27 日の NDVI 画像は全体的に NDVI が高い傾向があり、ほ場南西部でそれが特に顕著である。これは植物体の二次生長が当該エリアで著しく発生したためであり、地上部の画像からも全体的に発生していることが確認できる。一般的にバレイショの二次生長は、生育中期に激しい乾燥状態に晒されると土壤水分欠乏のために植物体の生育が止まり、塊茎の生長も停止するが、この後枯死しないうちに降雨等で土壤水分が上昇すると、植物体は再度生育をし始め生色を取り戻してくる。これはどの品種でも条件が揃うと発生するが、晩成種で特に発現が多い³⁹⁾。2017 年は 6 月までの降水量が少なく、7 月の降水量が多くなった年であったため⁴⁰⁾、7 月以降から全体的に二次生長が始まり、水尻側のほ場南西部で多発したと考えられる。すなわち、降雨による雨水がほ場南西部の水尻側に流れていき、土壤水分が上昇したために、枯死するはずの植物体が再度生育をし始めたといえる。

(2) NDVI 値と SPAD 値の関係

図 2-19 に NDVI 値，図 2-20 に SPAD 値の推移を示す。NDVI と SPAD とともに時期が進むにつれて値が小さくなった。これはバレイショの地上部が少しずつ黄化していき，光合成活性が低下していることを示している。また，7 月 20 日，27 日の NDVI 値，SPAD 値のばらつきが大きいことがわかる。これは前述の二次生長による影響で，黄化している葉と新葉が混在しているために引き起こされた。いずれの空撮日でも各プロットの NDVI 値に有意差 ($p < 0.05$) はなかった。

図 2-21 に NDVI と SPAD の相関関係を示す。決定係数 R^2 は 0.84 ($p < 0.05$) であった。SPAD 値は植物の葉に含まれるクロロフィル量を示す⁴¹⁾ことから，本モニタリングシステムはバレイショ地上部のクロロフィル量を空撮画像から推定することができる。

(3) 収量調査結果と NDVI との相関関係

表 2-3 にバレイショの収量を示す。各プロットの平均収量は，規格内品が 2863 kg/10a，規格外品が 1984 kg/10a となり，規格外収量のばらつきが大きい傾向があった。規格外品の内訳で多かったものは小玉，食害，軟腐病であった。

図 2-22～26 に収量と各空撮日ごとの NDVI 値の相関関係を示す。収量は 6 月 20 日の NDVI 値と最も相関が高く，負の相関関係が見られた ($R^2 = 0.52$)。

バレイショは着蕾期から開花始めにかけて塊茎を形成し，その後茎葉黄化までに塊茎を肥大化させる⁴²⁾ことから，この時期の生育状況が最終的な収量に影響を与えたと考えられる。しかし，NDVI値にはプロット間で有意差がなかったことから，単年度試験の結果では収量に影響を与えた要因が判然としなかった。この要因については，次章以降で検証する。

第4節 摘要

本章では空撮用マルチコプターとマルチスペクトルカメラを組み合わせたモニタリングシステムを構築し，バレイショ栽培におけるセンシングを行うことで以下の結論を得た。

1. 空撮 NDVI 画像から植生の違いや黄化の進行が確認された。
2. NDVI 値と SPAD 値は，時期が進むにつれて減少していき，両者に相関が見られた。
3. バレイショ収量は開花期における NDVI 値との相関が最も高く ($R^2 = 0.52$)，負の相関が見られた。
4. 本章で構築したモニタリングシステムは，バレイショ栽培におけるセンシングデバイスとして有用である。




図 2-1 試験ほ場と調査プロット



図 2-2 空撮用マルチコプター



図 2-3 マルチスペクトルカメラ




図 2-4 UAV のフレーム部



図 2-5 UAV のアーム部




図 2-6 UAV のボトム部

表 2-1 UAV の主要諸元

型式	S900
全長 (mm)	900
全高 (mm)	640
ペイロード (g)	8,200
飛行可能時間	約 10 分

表 2-2 マルチスペクトルカメラの主要諸元

寸法 (mm)	115.6 × 80.3 × 50
質量 (g)	400
分解能 (pixel)	1280 × 1024
画角 (W × H × D)	35.7 × 28.9 × 44.8
補足可能バンド	Blue (400-470 nm)
	Green (480-500 nm)
	Red (570-700 nm)
	NDVI Red (680 nm)
	Red Edge (720 nm)
	NDVI NIR (800nm)

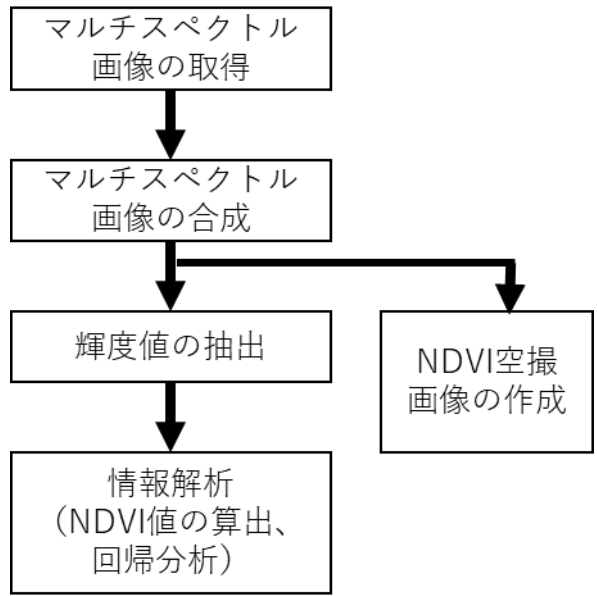



図 2-7 画像処理のフローチャート



☒ 2-8 Pixel Wrench2 の UI

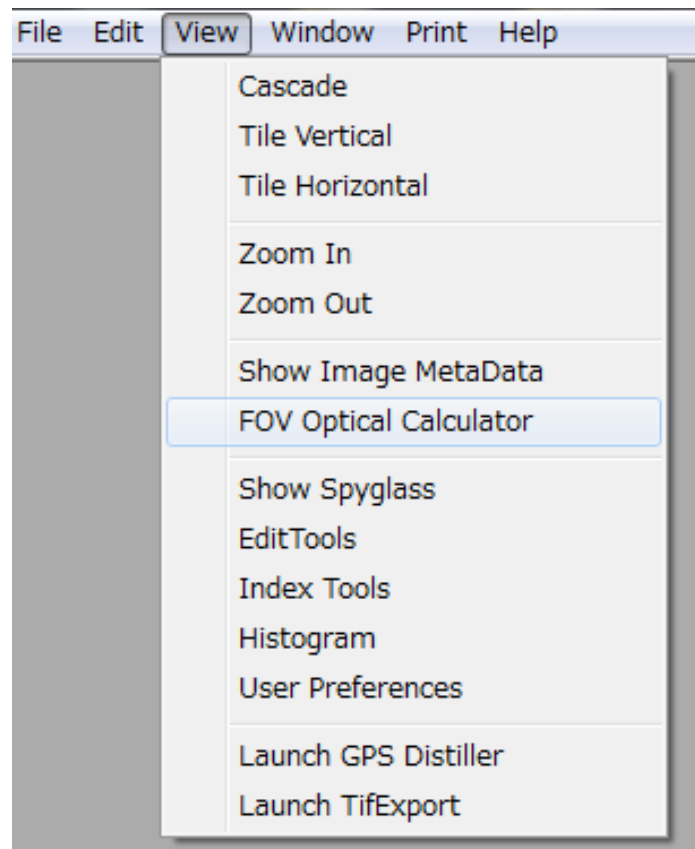


図 2-9 視差の補正①

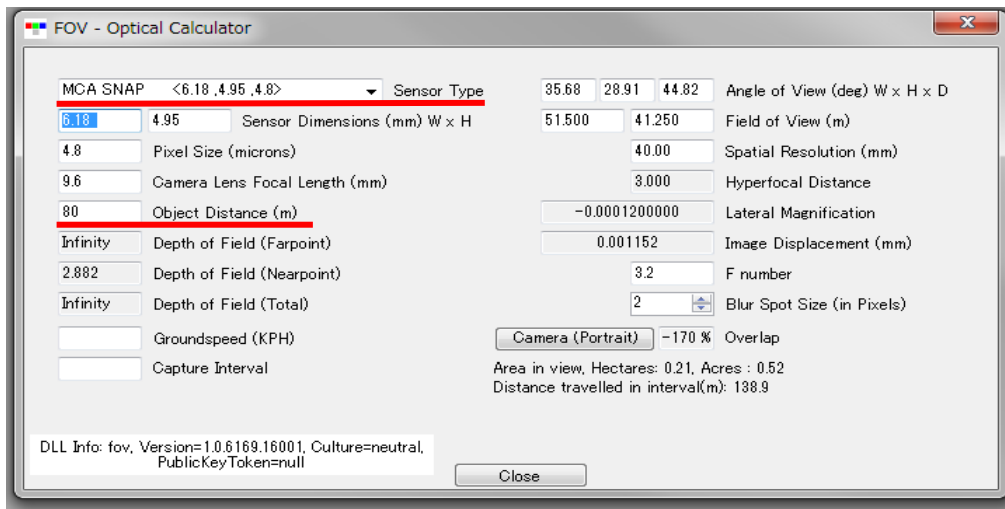


図 2-10 視差の補正②

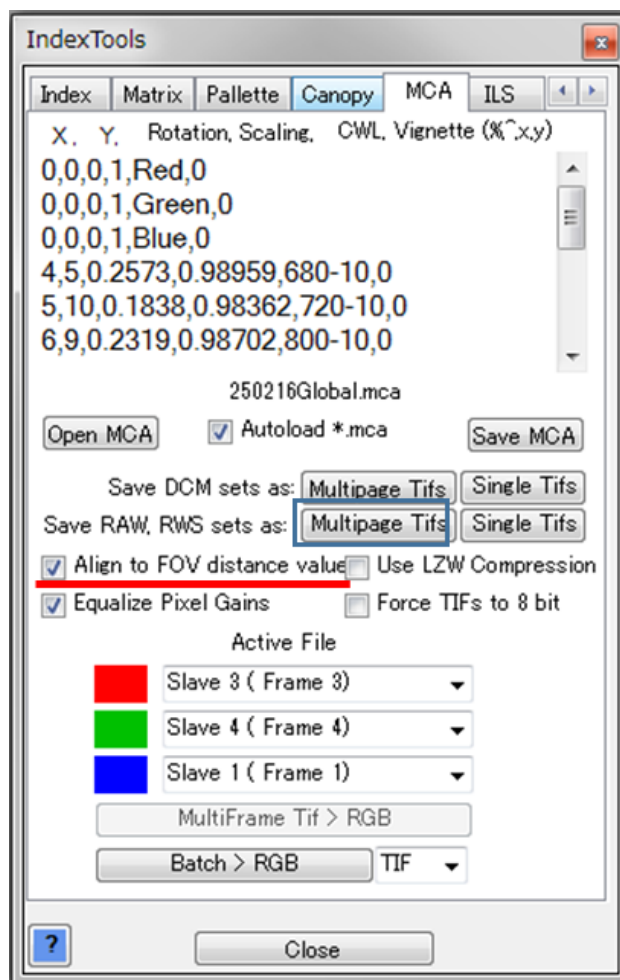


図 2-11 6 バンドの合成

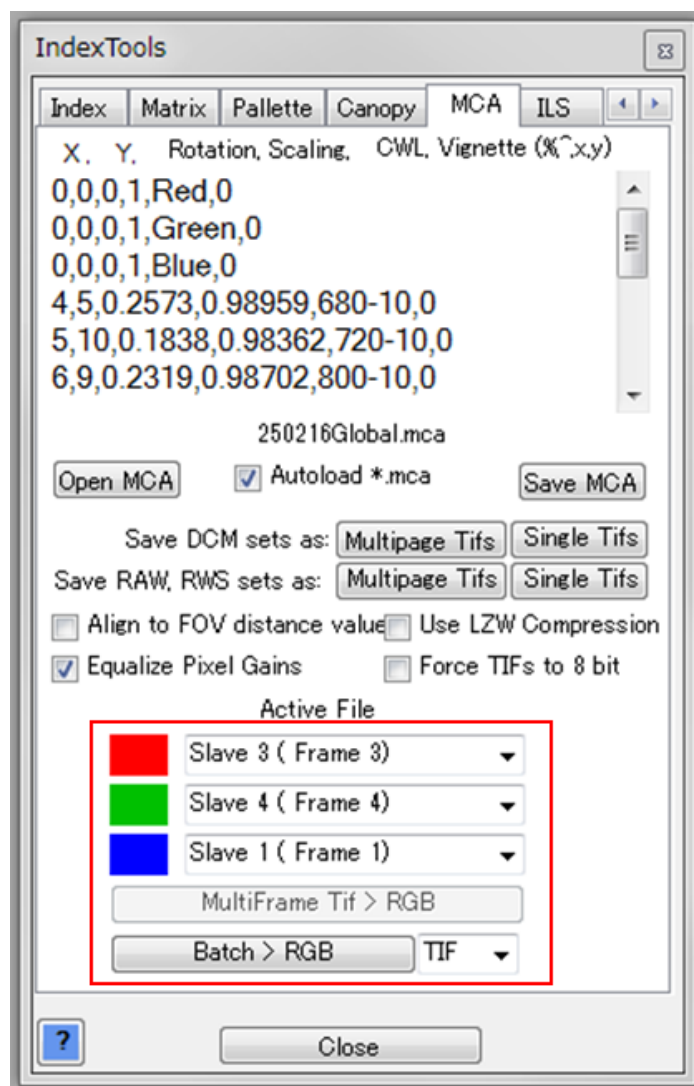


図 2-12 3 バンド疑似カラー画像の構築

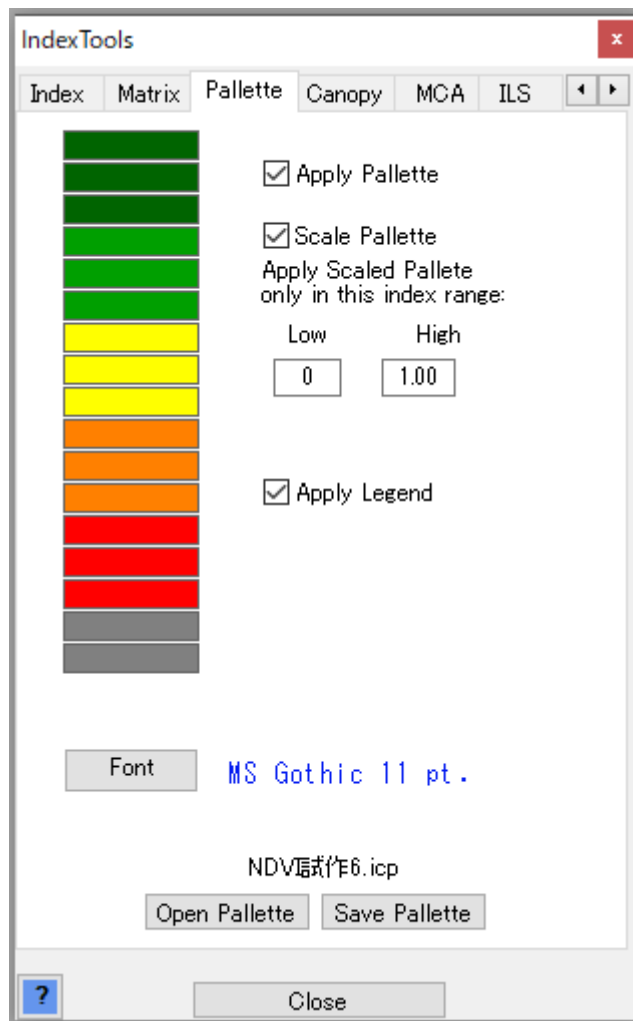


図 2-13 植生指数のカラースケール

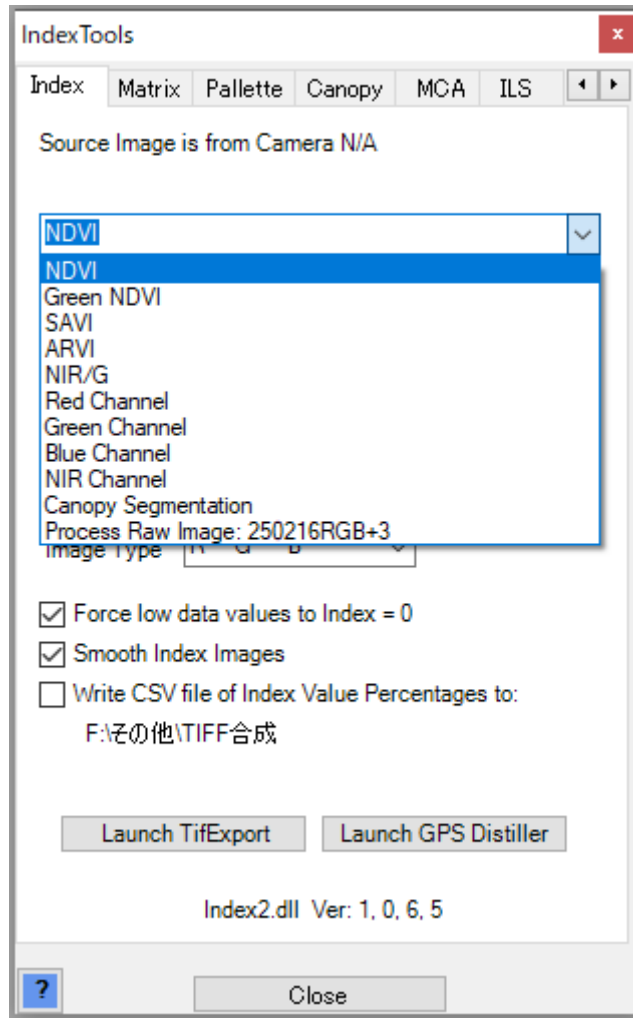


図 2-14 NDVI 空撮画像の作成①

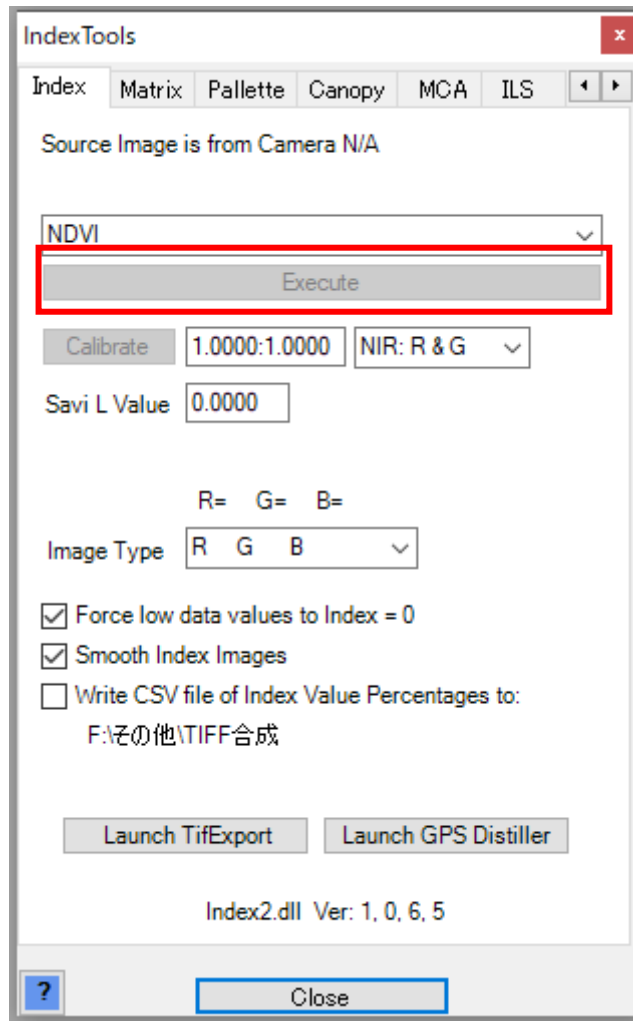


図 2-15 NDVI 空撮画像の作成②




图 2-16 RGB 空撮画像




图 2-17 NDVI 空撮画像

5月29日



6月6日



6月20日



7月13日



7月20日



7月27日



図 2-18 地上部の様子




図 2-19 NDVI 値 の 推 移




図 2-20 SPAD 値 の 推 移




図 2-21 NDVI と SPAD の 関係

表 2-3 収量調査結果

調査 プロット	収量 (kg/10a)		
	合計	規格内	規格外
A	3419	3075	345
B	4857	3420	1437
C	4958	2676	2282
D	5594	2857	2737
E	5071	2720	2351
F	6114	3257	2857
G	4143	2857	1286
H	4619	2045	2573




図 2-22 NDVI と収量 の 関係 (6 / 6)




図 2-23 NDVI と収量 の 関 係 (6 / 2 0)




図 2-24 NDVI と収量 の 関係 (7 / 13)




図 2-25 収量と NDVI の関係 (7/20)




図 2-26 収量と NDVI の関係 (7/27)

第 III 章 CNN を用いた画像の分類によるバレイシ ョ収量予測システムの開発

第 1 節 緒言

現在我が国の農業では農業従事者の減少，高齢化から，より効率的に栽培を行う精密農業，ICT 農業が注目されている。これらの技術体系で重要になるのがほ場内の情報を効率よく収集，解析し，その情報を栽培面にフィードバックすることである。その情報収集にはリモートセンシングが有効であり，これまでに人工衛星や航空機，UAV などの様々なプラットフォームにより事例が報告されている^{9)~13)}。特に近年では，フライトコントローラーの低価格化やセンサの小型化，性能向上といった背景から UAV の利用が拡大している。このプラットフォームは人工衛星や航空機と比較して，雲や大気の影響を受けづらく，高頻度でモニタリングが可能である点で優位である。前章において，中山間地域でのバレイシヨ栽培を想定した UAV ベースのモニタリングシステムの開発を行い，その有用性について評価した。その結果，構築したモニタリングシステムはバレイシヨ栽培に適用が可能であることが分かった。

また，近年コンピューターの処理速度の向上や ICT によるデータの蓄積から，CNN をはじめとした AI 技術が再注目されている。農業での ICT 化によって得られるデータへの AI 技術の適用も模索されて

おり，雑草の検出や病害の検出，作物種の分類など様々なタスクに対して応用した事例が報告されてきている⁴³⁾。しかし，農作物の収量予測に応用した事例は報告されていない。そこで，本章では UAV による空撮画像とバレイショ収量データを組み合わせたデータセットを CNN に学習させ，生育途中の画像から収量を推定するシステムの開発を目的とする。具体的には CNN を用いた画像の分類による収量予測モデル（以下画像分類 CNN モデル）を構築し，その予測精度について評価する。

第 2 節 材料と方法

(1) 実験場所と耕種概要

実験は山形県鶴岡市に位置する山形大学農学部附属やまがたフィールド科学センター（高坂農場）内（長辺：40 m，短辺：7.5 m，面積 3 a，土壌：灰色低地土）のほ場で行った。供試作物にはバレイショ（品種：トヨシロ）を用いた。定植は 2018 年 5 月 1 日に行った。条間は 0.75 m，株間は 0.30 m で栽植密度が 4.44 株/m²。定植前に土壌改良資材として牛糞糶殻堆肥を 3 kg/m²，苦土石灰を 100 g/m²，溶成りん肥を 40 g/m²，苦土重焼リンを 10 g/m² 散布した。施肥は基肥として高度化成肥料（14:14:14）を 2 g-N/m²~10 g-N/m²，追肥を硫安で 2 g-N/m² 行った。

(2) 試験区の構成

試験区は前記した基肥量と追肥を組み合わせ、施肥レベルの異なる A ~ F の 6 試験区を作成した。A 区は基肥 10 g-N/m^2 と追肥 2 g-N/m^2 、B 区は基肥 10 g-N/m^2 のみ、C 区は基肥 6 g-N/m^2 と追肥 2 g-N/m^2 、D 区は基肥 6 g-N/m^2 のみ、E 区は基肥 2 g-N/m^2 と追肥 2 g-N/m^2 、F 区は基肥 2 g-N/m^2 のみである。各試験区のほ場への配置を図 3-1 に示す。

(3) 実験機の構成と撮影条件

実験機は第 II 章で構築した空撮用マルチコプター (DJI 社, S900) とマルチスペクトルカメラ (Tetracam 社, microMCA RGB+3) によるモニタリングシステムを用いた (図 2-2)。それぞれの諸元は第 II 章表 2-1 および表 2-2 と同様である。

空撮作業はほ場全面を撮影するため、撮影高度を 30 m、オーバーラップ率 75 % 以上、サイドラップ率 60 % 以上に設定し行った。空撮画像の地上分解能は約 0.015 m/pixel となっている。空撮は太陽の南中高度が高い 10:00 から 14:00 までの間で、バレイショが萌芽してから 1 週間ごとに行った。空撮時にはあらかじめ生育調査を行う個体を選別して指標を立てた。空撮後の画像は 2 種の画像合成ソフト Pixel Wrench2 (Tetracam 社)、Photoscan (Agisoft 社) を用いて空撮画像の合成、オルソモザイク画像の作成を行った。オルソモザイク画像の解析では Photoscan を用いてラスタ演算で植生指数を算出しマッピング

グを行った。また，合成した画像からピクセルごとのバンド値を抽出し，地上部データとの照合を行った。

(4) 生育調査

生育調査は萌芽後から2週間ごとに行った。調査日は2018年5月28日，6月14日，6月25日，7月9日である。生育調査は各試験区で毎回3個体選定して行った。調査項目は草丈(m)，全重(g)，乾物重(g)である。

(5) 収量調査

バレイショの収量調査は2018年8月上旬に行った。収量調査はほ場内の各試験区内に1.8 m×1.8 mの調査プロットを各処理区に5個ずつ設け，そのプロットから4個体を収穫して行った。収量(kg/10a)は，プロットの1株当たり塊茎重と栽植密度との積から算出した。

(6) 収量予測

バレイショの収量予測には，生育データを基にした重回帰分析とCNNによる深層学習を用いた。

重回帰分析は収量(kg/10a)を目的変数とし，各生育調査日におけるプロット内の平均NDVI値と草丈を説明変数とした。統計ソフトはR(ver. 3.5.1)を使用した。

CNNによる収量予測モデルの構築は，ライブラリがChainerで，学習を行うためのGUIとして

CSLAIER (ver.0.7.0) を使用した。この GUI はブラウザベースのディープラーニングツールで、直感的にモデルの訓練とテストを行うことができる。訓練はいくつか収録されているニューラルネットワークモデルを選択して行うが、本研究では AlexNet を使用した。AlexNet は畳み込み層が 5 層、全結合層が 3 層の CNN である。一般的な CNN の中では比較的層が浅く、精度も良好であることからベンチマークとして現在も利用されている。農業分野において本 CNN を応用した事例としては、作物の病害検出や植物の識別などが報告されている⁴³⁾。

収量予測のデータセットとして、生育期間中に撮影した全 RGB 空撮画像から収量調査プロット部分をすべてトリミングし、プロット画像を時期別（生育期、開花期、黄化期）、さらに収量別（1-2 t/10a, 2-3 t/10a, 3-4 t/10a, 4-5 t/10a, 5-6 t/10a, 6-7 t/10a）にクラス分けを行った。プロット画像のサイズは 122×122 ピクセルである。また、モデルの汎化性能向上を目的に、90°、180°、270°回転、それを更に左右反転させるデータ拡張（Data Augmentation）を行った。拡張したデータセットは訓練用：テスト用＝9：1 に分割し、訓練とテストに供試した。データセットの内訳は表 3-1 のとおりである。なお、今回 5-6 t/10a に該当するプロットは該当なしのため、除外した。

収量予測モデルの総合的な精度評価は混同行列，正答率，適合率，再現率，F1値によって評価した。図3-2に混同行列の概略図を示す。以下にそれぞれの指標の説明と算出式，Aクラスの正解例を示す⁴⁴⁾。

正解率 (Accuracy) は，テストデータ数に対して，正解したものの割合を示す。

$$\text{正解率 (Accuracy)} = \frac{TA + TB + TC}{\text{テストデータ数}}$$

適合率 (Precision) は，特定のクラスであると予測した数に対して，本当に正しかったものの割合を示す。

$$\text{適合率 (Precision)} = \frac{TA}{TA + FA_B + FA_C}$$

再現率 (Recall) は，特定のクラスの正解データのうち正しく予測できたものの割合を示す。

$$\text{再現率 (Recall)} = \frac{TA}{TA + FB_A + FC_A}$$

F1値 (F1-measure) は Precision と Recall の調和平均を示す。

$$F1 \text{ 値} = \frac{2 * Precision * Recall}{Precision + Recall}$$

本試験では以上の指標をクラスごとに算出し，平均化することでモデルの評価を行った。本試験のデータセットのように，クラス間でデータ数の異なる不均衡なデータセットである場合，正解率はモデル

の精度を正しく示せないことがある。すなわち，予測モデルがデータ数の多いクラスに分類するだけで高い正解率を得てしまうという問題がある。そこで全体的なモデルの性能を表す指標として F1 値を使用した⁴⁵⁾。

学習モデルのテストは，過学習が発生した Epoch を特定するために，訓練データの精度が飽和した段階，学習が終了した段階，その中間の Epoch で行った。本稿では精度が飽和した段階でのテスト結果を示す。

第 3 節 結果と考察

(1) 空撮画像によるバレイショの生育状況

図 3-3 に各時期の RGB 空撮画像を示す。5 月 28 日の画像では，基肥の違いによる萌芽の違いが明瞭に確認できた。6 月 14 日では基肥の違いによる植被の大きさに違いが見られ，E 区と F 区の比較で追肥の有無による生育の違いが確認できた。6 月 25 日では A 区および B 区でさらに植被が大きくなっており，7 月 9 日の全試験区で黄化を始めている個体と緑色の濃い個体が混在していることが確認できた。緑色の濃い個体は新しい葉が伸長したことによる二次成長を示している。

図 3-4 に各時期の NDVI 空撮画像を示す。5 月 28 日の画像では RGB 画像と同様で萌芽の違いが明瞭

に確認できた。6月14日の画像では植被の違いが明瞭であるがNDVIに違いは見られない。6月25日の画像ではA区とB区で若干NDVIが高い傾向がみられる。7月9日の画像では、これまでの画像と比較してNDVIが均一であった。

図3-5に各処理区の平均NDVIの推移を示す。各処理区の平均NDVIはA区が0.62～0.79, B区が0.64～0.77, C区が0.64～0.73, D区が0.58～0.77, E区が0.53～0.77, F区が0.57～0.74に変化した。全処理区は平均NDVIの撮影時期別での変化が同様な傾向にあるが、4回目の調査では3回目でも下がった平均NDVIが再度上昇に転じている。3回目の調査時点ではほとんどの個体が黄化して平均NDVIが下がっていくが、4回目の調査時点では光合成活性の高い新しい葉が二次成長してきたため、平均NDVIが高くなった。

(2) 各試験区におけるバレイショの生育

図3-6に草丈の推移を示す。各処理区の草丈の推移は、A区が0.21 m～0.75 m, B区が0.19～0.67 m, C区が0.15 m～0.60 m, D区が0.17 m～0.57 m, E区が0.16 m～0.63 m, F区が0.21 m～0.55 mであった。生育初期では試験区間の差が小さかったが、生育が進行するに従い試験区間に差がついており、投入窒素量が草丈に影響を及ぼした。また、追肥を行っていないB区, D区, F区では4回目の生育調

査時に草丈の伸び率が低く，追肥が生育後期での草丈の伸長に影響を及ぼしたことを示している。

図 3-7 に植物体，塊茎を併せた全重の推移を示す。各処理区の全重の推移は，A 区が 52.6 ~ 1460.8 g，B 区が 55.7 ~ 775.2 g，C 区が 27.0 ~ 1004.9 g，D 区が 61.4 ~ 859.8，E 区が 21.8 ~ 725.8 g，F 区が 25.9 ~ 537.9 g となった。全重は各処理区で指数関数的に上昇する傾向が見られた。特に A 区が 4 回目の調査で急激に上昇した。生育の進行に伴って全重が急激に増加したのは，塊茎の着生と肥大が原因である。本年においてはバレイシヨの開花始めは生育調査の 2 回目であり，バレイシヨはこの時期から塊茎を着生し始めたため，全重が急激に増加した。渡辺によるとバレイシヨの作物体容積は地上部，塊茎ともに第 1 花房開花期から第 2 花房開花期にかけて急激に増大し，それ以降は塊茎が主に増大することを報告している⁴⁶⁾。一般的にバレイシヨの第 2 花房は，第 1 花房が 2 週間ほど開花した後に開花し始める⁴⁷⁾。本試験では，第 1 花房の開花期を 6 月 14 日とするとおよそ 2 週間後の 6 月 25 日で第 2 花房が開花し，この期間中は地上部および塊茎が増大し，6 月 25 日以降に塊茎が増大し，全重が急激に増加したといえる。

図 3-8 に植物体の乾物重の推移を示す。植物体乾物重は 2 回から 3 回目の調査間で変化がなく，3 回

目から 4 回目の調査間では A, B, C 区で数値が急増したが, D, E, F 区では増大しない傾向にあり, おおむね施肥量に比例して推移した。施肥条件と栽植密度を組み合わせたバレイシヨの栽培試験では, バレイシヨの乾物生産が葉面積指数と比例する関係にあり, 葉面積指数に対して施肥条件が影響することが報告されている⁴⁸⁾。本研究では, 空撮画像から各処理区の葉面積の違いが明らかになっており, 施肥条件の違いが葉面積, 乾物生産に影響を与えたことを示している。

図 3-9, 10, 11 に NDVI と草丈, 全重, 植物体乾物重との相関関係をそれぞれ示す。決定係数 R^2 はそれぞれ 0.58, 0.24, 0.41 となった。NDVI 値はすべての変数に対して開花期以降 0.8 付近で飽和した。Baret らは NDVI が植物の葉面積と関連があり, LAI (葉面積指数) の増加に伴って NDVI が飽和することが報告している⁴⁹⁾。バレイシヨの葉面積は, 田口らによると生育中期におおむね最大になるとされ⁴⁸⁾, 本試験において開花期以降で NDVI が飽和する結果に繋がった。

(3) 各試験区におけるバレイシヨの収量

表 3-2 に各試験区のバレイシヨ塊茎の収量を示す。A 区は 4230 kg/10a, B 区は 4371 kg/10a, C 区は 2543 kg/10a, D 区は 2913 kg/10a, E 区は 2936 kg/10a, F 区は 2061 kg/10a であった。谷口らは, トヨシロな

どの加工用バレイショは，低地土での窒素吸収量が多く，窒素施肥に対する収量への影響が判然としないことを報告している⁵⁰⁾。本試験で用いたほ場は灰色低地土で窒素吸収量が多くなり，施肥量に対して収量が比例しなかった。

(4) 収量と NDVI，草丈についての重回帰分析

各調査期別での収量と NDVI 値，草丈との重回帰分析結果を以下に示す。

$$Y = -4466.08 + 11380.94X_1 + 46.96X_2 \quad (5 \text{ 月 } 28 \text{ 日})$$

$$R^2 = -0.1252$$

$$Y = -15581 + 11699X_1 + 22240X_2 \quad (6 \text{ 月 } 14 \text{ 日})$$

$$R^2 = 0.9998$$

$$Y = -3397 - 3109X_1 + 15953X_2 \quad (6 \text{ 月 } 25 \text{ 日})$$

$$R^2 = 0.8199$$

$$Y = -10917.02 + 11394X_1 + 8636X_2 \quad (7 \text{ 月 } 9 \text{ 日})$$

$$R^2 = 0.5835$$

ここで， Y ：収量（kg/10a）， X_1 ：NDVI 値， X_2 ：草丈（m）である。

草丈と NDVI 値を説明変数とした重回帰分析での 6 月 14 日（開花初期）と 6 月 25 日（開花後期）で予測精度が高いことは，開花期における草丈の伸長度合いと光合成活性が最終的な収量に影響を及ぼしていることを示している。横堀らはバレイショ

(トヨシロ)の生育地図を作成するために、開花期の草丈と葉身中のクロロフィル含量を掛け合わせた指数を総クロロフィル含量とし、規格内収量(kg/ha)やデンプン価(%)との関係を調査している。その結果、バレイショの規格内収量は、一定水準以下の総クロロフィル含量と高い相関があることを報告しており、本試験においても草丈とNDVIデータを基にした重回帰分析で収量を高い精度で予測できた²⁸⁾。

(5) 画像分類 CNN モデルによる収量予測精度

図 3-11 に生育期収量予測モデルの学習の推移を示す。生育期でのモデルは Epoch 250 までに訓練データでの正答率は 1.0 付近で飽和した。誤差は徐々に低下し、最終的に 0 付近で飽和した。また、精度と誤差は、開花期や黄化期でも同様に Epoch 250 までに飽和した。

表 3-3, 3-4, 3-5 に生育期, 開花期, 黄化期の収量予測モデルの混同行列を示す。表 3-6 にそれぞれのモデルの正解率, 適合率, 再現率, F1 値の結果を示す。混同行列の結果から, 1-2 t/10a, 6-7 t/10a のクラスでは, 各モデルとも収量を予測できなかった。これは, これらのクラスの画像データセットが他のクラスより極端に少ない状態, すなわち不均衡なデータセットであることが原因である。一般的に, 不均衡なデータセットによるモデルでは少数派の予

測精度が悪化することが知られている。これを回避するためには，少数派データのオーバーサンプリング，多数派データのアンダーサンプリング等のデータレベルでの手法や学習器のアルゴリズムを修正する手法，またはこれらを組み合わせる手法が有効であることが示されており⁵¹⁾，それを取り入れた検証を行う必要がある。また，収量予測結果は多数派である 2-3 t/10a，3-4 t/10a，4-5 t/10a のクラスであってもばらつく傾向にあり，生育期で 2-3 t/10a と 4-5 t/10a のクラス，開花期で 2-3 t/10a と 3-4 t/10a のクラスに偏る傾向が見られた。また，黄化期では，クラス間の違いがほとんどなかったため，収量予測結果が 3-4 t/10a に集中した。

各モデルの再現率，適合率，F1 値は，生育期のモデルがそれぞれ 0.39，0.36，0.28 で，開花期のモデルが 0.29，0.28，0.19，黄化期が 0.07，0.19，0.10 と，生育期のモデルが最も高い値を示したが，重回帰分析の結果と比較して予測精度が低かった。AI での収量予測が低かった要因としては，すべてのモデルでの過学習にあると考えられる。この傾向は各 Epoch で学習が飽和する前に発生している。過学習の原因としては，データセットの量と質，データセットに対するモデルの構造がある。データセットの量や質は，データ数を増やす，不均衡をなくすようにリサンプリングするなどが解決策としてあげられるが，

データセットを増やすことが困難な場合はニューラルネットワークモデルの構造を変更することも選択肢に入る。小規模なデータセットで学習を行う場合，事前に訓練されたネットワークを活用した転移学習手法が有効であることが示されている⁵²⁾。中でも Fine tuning という手法が広く用いられている。これは事前に学習済みモデルの全結合層を変更し，そのパラメーターを初期値として学習を進める手法である。一般的に，CNN は初期値依存性が強く，特に訓練データが少ない場合はより良い初期値を得ることが過学習を防ぎ良い学習結果を得るために重要である⁵³⁾。

今後は以上の改善を施すことで，空撮画像を用いた収量予測モデルを重回帰分析の精度と同等以上にする必要はある。

第 4 節 摘要

本研究では，施肥条件を 6 段階に設定したバレイショほ場で栽培試験を行い，UAV で取得した空撮画像情報と収量データから CNN を用いた画像の分類による収量予測モデルの構築と精度評価を行った。その結果，以下のことが明らかになった。

- 1) UAV を用いたバレイショの空撮では，施肥条件の違いによって植被の違いを確認できたが，NDVI に処理区間差は見られなかった。

- 2) 加工用バレイショは生育の進行に伴って草丈に処理区間差が生じた。
- 3) 加工用バレイショの収量は，施肥量に比例しない傾向にあった。
- 4) 加工用バレイショの収量予測では，生育期と開花期の NDVI データ，草丈のデータを基にした重回帰分析で高い精度を示した。
- 5) CNN を用いた画像の分類による収量予測モデルは，データセットのクラス間でのサンプルの不均衡や過学習によって予測精度が低かった。精度の良好な学習を行うためには，クラスごとのサンプル数をそろえる，転移学習による CNN 自体の改善など必要である。

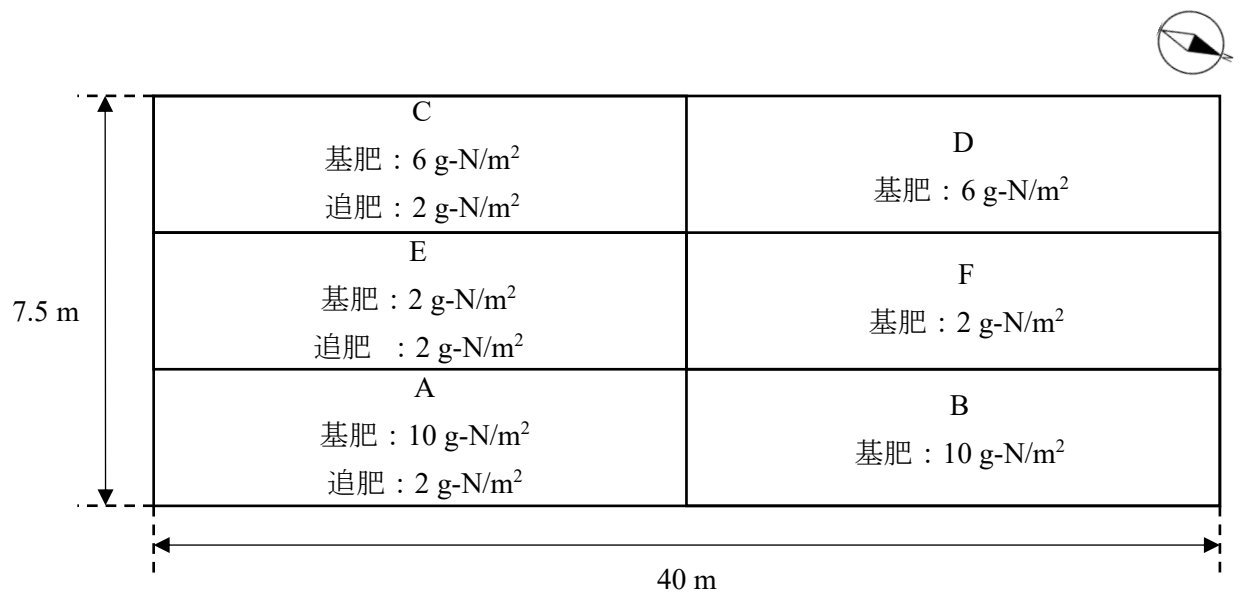


図 3-1 試験区設定

表 3-1 データセットの構成

	訓練	テスト
1-2 t/10a	45	5
2-3 t/10a	225	25
3-4 t/10a	216	24
4-5 t/10a	135	15
6-7 t/10a	27	3
合計	648	72

		予測されたクラス		
		A	B	C
実際のクラス	A	TA	FB _A	FC _A
	B	FA _B	TB	FC _B
	C	FA _C	FB _C	TC

■ 正解 ■ 不正解

注：Tは正解，Fは不正解，行は真のラベル，列は予測ラベルをそれぞれ示す。

図 3-2 混合行列の模式図

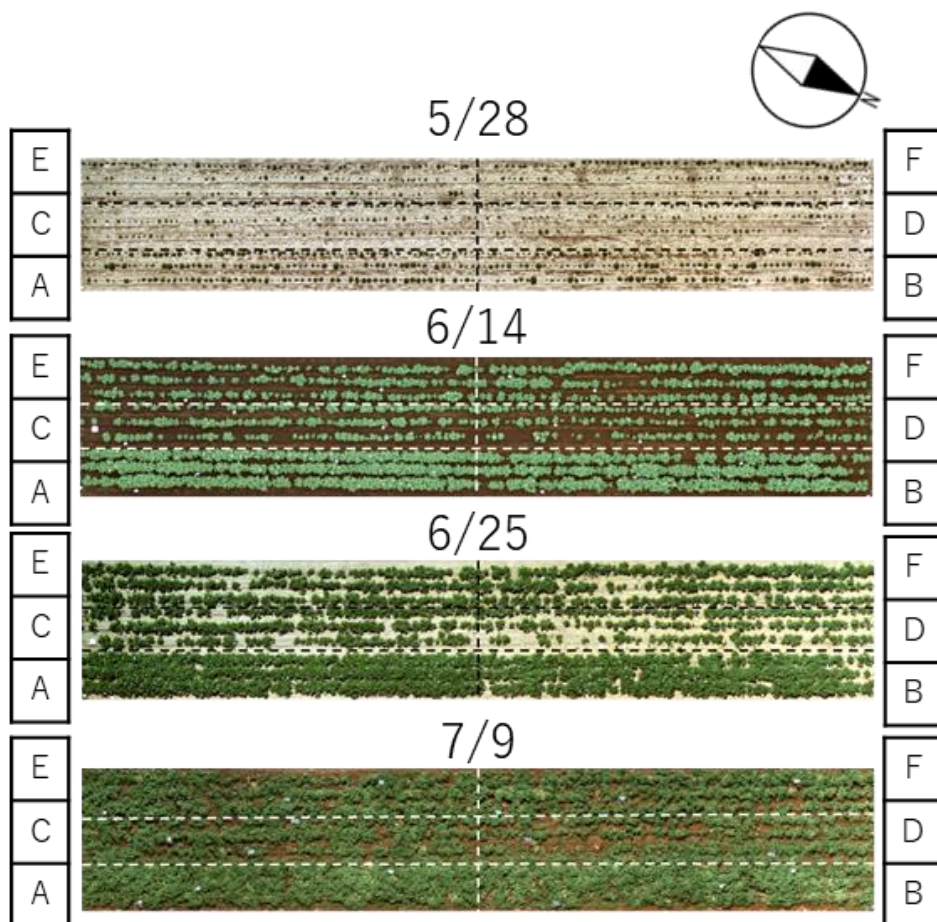


図 3-3 バレイショほ場での RGB 空撮画像

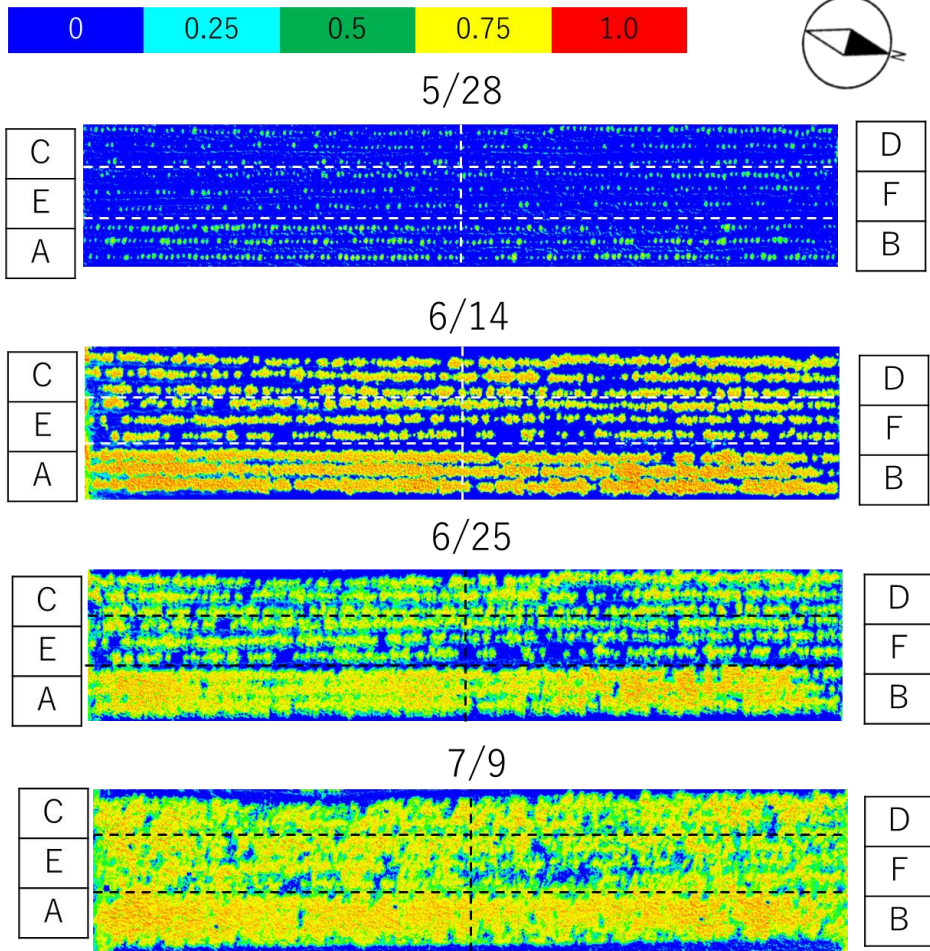


図 3-4 バレイショほ場での NDVI 空撮画像




図 3-5 バレイショ生育期間内の NDVI 値の推移




図 3-6 バレイショ生育期間内の草丈の推移




図 3-7 バレイショ生育期間内の全重の推移




図 3-8 バレイショ生育期間内の植物体乾物重の推移




図 3-9 NDVI 値と草丈の相関関係




図 3-10 NDVI 値と全重の相関関係




図 3-11 NDVI 値と植物体乾物重の相関関係

表 3-2 収量調査結果

試験区	収量 (kg/10a)
A	4230 (515.0)
B	4371 (1252.1)
C	2543 (667.5)
D	2913 (824.5)
E	2936 (343.6)
F	2061 (738.1)

注：() 内数値は標準偏差を示す




図 3-11 学習の推移 (生育期)

表 3-3 生育期の収量予測モデルの混同行列

生育期 (Epoch 100)	予測				
	1-2 t/10a	2-3 t/10a	3-4 t/10a	4-5 t/10a	6-7 t/10a
1-2 t/10a	0	2	0	3	0
2-3 t/10a	0	17	0	8	0
正解 3-4 t/10a	0	7	3	14	0
4-5 t/10a	0	0	0	15	0
6-7 t/10a	0	3	0	0	0

表 3-4 開花期の収量予測モデルの混同行列

開花期 (Epoch 100)	予測				
	1-2 t/10a	2-3 t/10a	3-4 t/10a	4-5 t/10a	6-7 t/10a
1-2 t/10a	0	4	1	0	0
2-3 t/10a	0	18	4	0	0
正解 3-4 t/10a	0	13	9	2	0
4-5 t/10a	0	6	6	3	0
6-7 t/10a	0	2	1	0	0

表 3-5 黄化期の収量予測モデルの混同行列

黄化期 (Epoch 140)	予測				
	1-2 t/10a	2-3 t/10a	3-4 t/10a	4-5 t/10a	6-7 t/10a
1-2 t/10a	0	0	5	0	0
2-3 t/10a	0	0	25	0	0
正解 3-4 t/10a	0	1	23	0	0
4-5 t/10a	0	1	14	0	0
6-7 t/10a	0	0	3	0	0

表 3-6 収量予測モデルの精度評価

	正解率	適合率	再現率	F1 値
生育期	0.49	0.39	0.36	0.28
開花期	0.42	0.29	0.28	0.19
黄化期	0.32	0.07	0.19	0.10

第IV章 CNNを用いた画像の回帰によるバレイショ収量予測システムの開発

第1節 緒言

現在我が国の農業では農業従事者の減少や高齢化といった背景から、より効率的に栽培を行う精密農業、ICT農業が注目されている。これらの栽培技術体系にはほ場内のデータを効率よく収集し、そこから得られた情報を解析することで栽培へフィードバックする技術が必要になる。これにはリモートセンシングが有効で、これまでも人工衛星や航空機、近年では UAV を用いた事例が多数報告されている^{9)~13)}。また、リモートセンシングで収集したデータの解析には機械学習が有効である。機械学習手法に関して、近年大規模データセットやコンピュータの計算処理能力の向上などを背景として CNN が注目されている¹⁴⁾。CNN は現在様々な分野での応用が模索されており、農業分野でも雑草の検出や作物の分類など様々なタスクに応用がなされている⁴³⁾。しかし CNN 技術を農作物の収量予測に応用した事例はほとんどない。

筆者らはバレイショを対象に UAV 空撮画像と収量データを組み合わせたデータセットから、画像分類 CNN モデルによる収量予測モデルの構築と精度評価を行った。その結果、構築した収量予測モデルは、データセットのクラス間でのサンプルの不均衡や過学習によって予測精度が低かった。予測精度を向上するには、クラスごとのサンプル数をそろえる、Fine tuning を始めとした転移学

習による CNN 自体の改善が必要であることが明らかになった⁵⁴⁾。Fine tuning は事前学習済みの CNN モデルの全結合層を変更し、学習済みの重みデータを初期値として再学習する手法で、一から学習するよりも良い精度が得られることで知られている⁵³⁾。しかし、画像分類手法のようなマルチクラス分類はクラスラベルが互いに独立しているとみなされるため、クラス間に順序関係がある場合は不適であるとされている⁵⁵⁾。このようなタスクに対しては、分類手法でなく回帰手法が有効である。CNN を用いた回帰手法は、食事画像からカロリー量を推定するという事例が報告されている⁵⁶⁾。

そこで、本章では前章での画像分類手法による収量予測モデルを見直し、Fine tuning および回帰手法を組み合わせることで、より精度の高いバレイショの収量予測手法の確立を目的とする。本稿では新たに構築した CNN を用いた画像の回帰による収量予測モデル（以下、画像回帰 CNN モデル）による収量予測手法と従来のバレイショの生育量（草丈や NDVI）から収量を予測する手法での精度の比較を行った。

第 2 節 材料と方法

(1) 実験場所と耕種概要

実験は山形県鶴岡市に位置する山形大学農学部附属やまがたフィールド科学センター（高坂農場）内のほ場（長辺：40 m，短辺：7.5 m，面積 3 a）で行った。供試作物

はバレイショ（品種：男爵薯）を用いた。定植は2019年4月24日に行った。栽培条件，土壤改良，施肥体系は第Ⅲ章の試験と同様に行った。

(2) 試験区の構成

試験区は第Ⅲ章の試験と同様の試験区を作成した。各試験区のほ場への配置は図3-1と同様である。

(3) 実験機の構成と撮影条件

実験機は第Ⅱ章で構築した空撮用マルチコプター（DJI社，S900）とマルチスペクトルカメラ（Tetracam社，microMCA RGB+3）を組み合わせたモニタリングシステムを用いた（図2-2）。それぞれの諸元は第Ⅱ章表2-1，表2-2と同様である。

空撮作業は前年と同様の手法で行った。撮影日は2019年5月30日，6月6日，10日，13日，18日，20日（着蕾～開花後期）に行った。空撮は太陽の南中高度が高い10：00～14：00の間に4回ずつ撮影を行った（6月6日のみ天候の影響で2回）。空撮後の画像合成，解析は前年度の試験と同様に行った。

(4) 生育調査と収量調査

生育調査は空撮画像の取得と同日に行った。調査項目は草丈（m），茎数，分枝数である。収量調査は2019年8月6日に行った。生育調査，収量調査は定植後に2.2 m×2.2 mの調査プロット（各処理区3つずつ）から5個体を選定して行った。調査項目は収量（kg/10a）と1株当たりの塊茎数である。収量はプロットの1株当たり塊茎

重と栽植密度との積から算出し，1株当たりの塊茎数は調査株から得られた塊茎数から株数を除して算出した。生育，収量の各項目の処理区における多重比較には Tukey-Kramer 検定を利用した。統計ソフトは R(ver. 3.5.1) を使用した。

(5) 回帰分析

CNN によるバレイショの収量予測モデルの比較として重回帰分析と単回帰分析を行った。

重回帰分析は収量 (kg/10a) を目的変数とし，各生育調査日におけるプロット内の平均 NDVI 値と草丈を説明変数とした。説明変数の二つの因子は，前報のトヨシロでの重回帰分析結果で草丈の因子が強かったことから選択した。単回帰分析は，収量 (kg/10a) を目的変数とし，各生育調査日におけるプロット内の草丈を説明変数とした。統計ソフトは R (ver. 3.5.1) を使用した。

(6) CNN の概要

AI の学習環境は表 4-1 のとおりである。ライブラリは Keras (ver.2.2.4) を使用した。Keras は Python のニューラルネットライブラリで，直感的で簡潔にコードを書くことができる。このライブラリには後述する VGG16 などの CNN や ImageNet などのデータセットを比較的簡単なコードでダウンロードし，利用することが可能である。

構築した CNN は，畳み込み層の部分に事前学習済みのモデルとして VGG16 (畳み込み層のみの 13 層) を使用し，さらに新規に 2 層の全結合層を 2 層加えた 15 層の

CNN を使用した（図 4-1）。重みデータは ImageNet を使用した。事前学習のパラメーターである重みデータは ImageNet のものを使用した。ImageNet は画像認識用のデータセットで、1400 万枚を超える画像群と画像に写っている物体名（クラス名）が紐づけられたデータセットである。Fine tuning を始めとした転移学習では、ImageNet などのデータセットで事前学習した重みを使用することになる。この事前学習用重みデータは、対象となるタスクに応じて選択する必要がある。すなわち、本試験のように対象物が植物体である場合は、データセット中に植物の画像が含まれていることが望ましい。ImageNet は植物の画像も多く含まれていることから、本試験における事前学習用データセットとして適していると判断した。本試験ではこの重みデータを入力側から 10 層目までの畳み込み層の重みを固定して、以降の層の重みを調整して学習を行った。CNN の畳み込み部分は層が深くなるにつれて点や線といった低次元の概念の特徴から高次元な概念の特徴（顔画像の場合は目や鼻など）に注目するようになる⁵⁷⁾。Fine tuning の場合は、事前学習させた重みデータのうち、入力層に近い層の重みが変わらないように固定し、出力層に近い層の重みを入力データに適応するように変化させることになる。したがって、低次元の特徴は汎用的な畳み込み層で、高次元の特徴は入力データに適応した畳み込み層で特徴を抽出することが可能になる。これによって少ない学習データからでも十分な学

習が可能になる。

損失関数は RMSE (二乗平均平方根誤差) を使用した。Epoch は 500 である。RMSE は、観測値を y_i ($i=1, 2, 3, \dots, n$)、モデルから計算した計算値 (予測値) を \hat{y}_i とすると以下の計算式で定義される。CNN はモデルが算出した予測値と教師データの実測値との差を最小にするように誤差逆伝播法によって各層の重みを更新することで学習を行っていく。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

(7) データセットの構成

AI に学習させるデータセットとして、着蓄～開花期に撮影した全 RGB 空撮オルソ画像から収量調査プロット部分をすべてトリミングした。プロット画像の一例を図 4-2 に示す。プロット画像は、施肥条件の違いによって植被に違いが見られた。プロット画像は 90 度、180 度、270 度回転させ、さらに左右反転させてデータ拡張を行った。本試験では 1 日に複数回空撮画像の取得を行ったが、日射条件の補正等を行わなかった。これは CNN に学習させたときに、条件の異なる日射条件の画像を加えることで汎化性能を高めるためである。プロット画像の解像度は変更しなかった。

画像データに対するラベルデータはプロットに対応する収量を記録した CSV データを作成し、画像と収量デー

データを併せてデータセットとした。データセットは訓練用とテスト用に 9:1 に分割し、学習とテストにそれぞれ供試した。また、訓練用データは、学習時にさらに訓練と検証に 8:2 に分割して学習を行った。データセットの構成は図 4-3 に示す。

(8) 画像回帰 CNN モデルの精度評価

画像回帰 CNN モデルの精度はテストデータでの予測収量 (kg/10a) と実収量 (kg/10a) の相関で評価を行った。

第 3 節 実験結果と考察

(1) 空撮画像によるバレイショの生育状況

図 4-4 に各時期の RGB 空撮画像を示す。RGB 空撮画像からは 6 月 6 日から開花が確認できる。地上部の生育は 5 月 30 日の画像で投入施肥量の違いによる植被への影響が出ており、E、F 区で植被が小さい傾向にあった。その後、生育は時期の進行とともに盛んになり、全処理区で畝間が確認できないほど植被が大きくなった。渡辺はバレイショの生育に関し、第一花房開花期から第二花房開花期にかけて、作物体容積が急激に増加し、空間に占める容積割合が第二花房開花期で最大になることを示している⁴⁶⁾。一般的なバレイショ品種の花房は、第一花房が 2 週間ほど開花した後で第二花房が開花してくる⁴⁷⁾。本試験では第一花房の開花が 6 月 6 日ごろと考えられ、およそ 2 週間後の 6 月 18 日、20 日ごろに作物体容積が急激に増加したことで植被が増加したといえ

る。

施肥条件の多少に伴う植被の差は，前章の開花期におけるトヨシロの空撮画像と比較してトヨシロで大きく，男爵薯で小さいことがわかる。国分らはバレイショの主要5品種を供試し，施肥量を4水準設けた栽培試験を行っており，それによるとトヨシロは施肥量増加に伴って地上部生育量の増加が大きく，男爵薯では施肥量増加に伴う地上部生育量の増加は相対的に小さいことを示しており⁵⁸⁾，本試験の結果と合致する。

図4-5にNDVIをマッピングした空撮画像を，図4-6にNDVI値の推移をそれぞれ示す。5月30日のF区では他の処理区と有意差($p < 0.05$)が確認されたが，それ以降のNDVI値には処理区で差がなかった。NDVIの推移としては5月30日から6月6日にかけて増加し，6月13日までは横ばいであり6月18日，20日にピークを迎えた。既往の研究では，バレイショの葉内クロロフィル量は開花盛期において，特に上位葉で全生育期間中でも最大量に達することが報告されている⁵⁹⁾。本試験のような空撮画像のモニタリングでは，主に上位葉を観測していると考えられるので，NDVI値が漸増していった。また，窒素量の違いによるバレイショのNDVI，GNDVI (Green Normalized Difference Vegetation Index) の変化を調査した研究では，6月上旬から8月下旬の生育期において，窒素量が最小の試験区以外で差が見られなかったことを報告している⁶⁰⁾。したがって本研究でも，処理区間での

NDVI 値には差が見られなかった。

(2) 各試験区におけるバレイシヨの生育

図 4-7 に各処理区の草丈の推移を示す。各処理区の草丈の推移は，A 区が 0.39 ~ 0.67 m，B 区が 0.41 ~ 0.63 m，C 区が 0.39 ~ 0.64 m，D 区が 0.38 ~ 0.58 m，E 区が 0.35 ~ 0.56 m，F 区が 0.34 ~ 0.48 m の間で推移し，いずれの処理区でも 6 月中旬に最高点に達した。バレイシヨは施肥量が多いほど生育が促進され，開花期で最高点に達することが報告されており⁵⁹⁾，本試験もその結果と同様であった。

図 4-8 に各処理区の茎数を示す。茎数はいずれの調査日でも約 4~5 本であり，処理区間に有意差が見られなかった。バレイシヨ早生品種の茎数は 4~5 本が一般的であり，種芋の状況や貯蔵条件によって大きく規制されることが報告されている⁶¹⁾ことから，施肥条件に影響されなかったといえる。

図 4-9 に各処理区の分枝数の積算値を示す。積算分枝数は A 区が 25.1 本，B 区が 23.0 本，C 区が 23.8 本，D 区が 16.8 本，E 区が 14.3 本，F 区が 8.9 本と投入施肥量に応じて増加する傾向にあった。大崎らはバレイシヨの分枝は施肥量の増加に伴い，10 葉節より上位節で生育が促進されることを報告しており⁶²⁾，施肥量の違いによって上位葉節での分枝が増加したため，分枝数に差が出たと考えられる。

(3) 各試験区におけるバレイシヨの収量

表 4-2 に各処理区における単位面積当たりの収量と塊茎数を示す。各処理区の収量は A 区が 5853 kg/10a, B 区が 5026 kg/10a, C 区が 4944 kg/10a, D 区が 4111 kg/10a, E 区が 3846 kg/10a, F 区が 2828 kg/10a で, 投入施肥量に対して比例した。塊茎数はすべての処理区で有意な差がなかった。このことからバレイショ栽培における施肥条件の違いは宗友らによる男爵薯での研究⁶³⁾に示すとおり, 一株あたりの塊茎数に影響を与えず, 塊茎重に影響を与えたといえる。また, A 区と B 区の収量は, ばらつきが大きい傾向にあった。比較的高施肥条件である A 区と B 区は田口らが示すとおり⁴⁸⁾, 植物体の葉面積が過剰に増大したことによって, 葉同士の間による相互遮蔽による受光能率の低下やそれによる下層葉, 非同化部位の呼吸の増加などで乾物生産効率が低下し, 塊茎への光合成産物の転流量が減少して引き起こされたといえる。

前章でのトヨシロでの結果と比較し, 単位面積当たり収量と一株当たり塊茎数はトヨシロよりも男爵薯の方が多く, 特に品種による一株当たり塊茎数の違いが単収に大きく影響した。バレイショの塊茎数を制限する要因は, 1 茎当たりの匍枝数と株当たり茎数で, 特に後者は地上部の生育の立体的構造と株当たり塊茎数に密接な関係があり, 株当たり茎数が少ない場合に大型の塊茎を着生する傾向にある⁶⁴⁾。2018 年のトヨシロほ場と 2019 年の男爵薯ほ場の着蕾期の空撮画像を比較すると, 植被の大き

さが男爵薯の方が明確に大きいうえにばらつきも小さい。当該期間は分枝の発生も少ないことから、植被の大きさに最も影響を与えている要素は茎数であると考えられるので、トヨシロよりも植被が大きく安定している男爵者は株当たり塊茎数が多く、処理区やプロット間でのばらつきが小さかった。以上のことから、男爵薯は日本海側の気候でも比較的茎数を安定させることが容易であり、株当たり塊茎数が確保しやすく、かつ安定した収量を確保できる特徴を持っている。

(4) 回帰分析

各調査日別の収量と NDVI 値，草丈との重回帰分析結果を以下に示す。

$$Y = -170998.9 + 19418.5X_1 + 245.0X_2 \quad (5/30)$$

$$R^2 = 0.46$$

$$Y = -2896.50 - 5072.20X_1 + 228.50X_2 \quad (6/6)$$

$$R^2 = 0.69$$

$$Y = -328.74 - 8060.74X_1 + 191.43X_2 \quad (6/10)$$

$$R^2 = 0.80$$

$$Y = -9051.13 + 7510.75X_1 + 159.21X_2 \quad (6/13)$$

$$R^2 = 0.79$$

$$Y = 7241.80 - 17665.56X_1 + 181.97X_2 \quad (6/18)$$

$$R^2 = 0.82$$

$$Y = -6599.32 + 2548.84X_1 + 166.32X_2 \quad (6/20)$$

$$R^2 = 0.74$$

ここで， Y ：収量（kg/10a）， X_1 ：NDVI 値， X_2 ：草丈（m）である。

開花期における各調査日の NDVI 値，草丈から単位面積当たり収量を高い精度で予測できた。しかし，前述の NDVI 値の調査から NDVI の寄与が小さいと考えられる。そこで，説明変数を草丈，目的変数を単位面積当たり収量とした単回帰分析を行った。その結果を以下に示す。

$$Y=284.497X-6300.5 \quad (5/30)$$

$$R^2 = 0.44$$

$$Y=201.8074X-5575.12 \quad (6/6)$$

$$R^2 = 0.70$$

$$Y=170.3722X-5059.94 \quad (6/10)$$

$$R^2 = 0.81$$

$$Y=142.5135X-3801.96 \quad (6/13)$$

$$R^2 = 0.78$$

$$Y=152.1388X-4541.66 \quad (6/18)$$

$$R^2 = 0.80$$

$$Y=148.2357X-6204.32 \quad (6/20)$$

$$R^2 = 0.75$$

以上のように男爵薯はトヨシロと比較して，最終的な収量への草丈の寄与率が高いことがわかる。このよう

に，男爵薯は開花期における草丈が，最終的な収量に最も影響を及ぼすことがわかる。一般的にバレイショは，茎葉を構成している炭素の多くが塊茎の肥大に際してかなり転流する⁶⁵⁾ことから，塊茎肥大盛期である開花期の生育状況が収量に影響を及ぼした。したがって，男爵薯は開花期における草丈を基にした回帰分析が収量予測に有効といえる。

(5) 画像回帰 CNN モデルによる収量予測

図 4-10 に 5 月 30 日の収量予測モデルの学習の推移を示す。青い線は訓練データによる Loss の推移，オレンジの線は検証データによる Loss の推移をそれぞれ示している。収量予測モデルは 500 回学習させることで十分に学習が収束しており，二つの線が重なっていることから過学習が発生していないといえる。RMSE は 500 付近で収束しており，訓練と検証データによる予測収量の誤差平均が 500 kg/10a といえる。この傾向はいずれのモデルでも同様であり，すべての画像回帰 CNN モデルで十分な学習ができた。

図 4-11～16 に各画像回帰 CNN モデルでのテストデータの予測精度を示す。決定係数 R^2 は 5 月 30 日が 0.90，6 月 6 日が 0.93，6 月 10 日が 0.92，6 月 13 日が 0.82，6 月 18 日が 0.95，6 月 20 日が 0.93 となった。 R^2 はいずれの画像回帰 CNN モデルとも高く，予測精度が高いことを示している。

しかし，実収量が 6000 kg/10a 以上では誤差が大きく

なり，予測収量が実収量よりも過小に予測される傾向が見られた。実収量で 6000 kg/10a 以上のプロットは，比較的高施肥条件である A 区，B 区の一部で見られており，処理区間で収量のばらつきが大きかった。各処理区内のプロットで植被が同程度である場合，A 区と B 区ではプロットごとでの実収量のばらつきによって予測収量の変位も大きくなったと考えられる。しかし，山形県におけるバレイショの 10a 当たりの平均収量は 1750 kg/10a である⁶⁶⁾ことから，実利用を考えた場合にその影響は少ないと考えられる。

図 4-17 に重回帰分析と画像回帰 CNN モデルの決定係数の比較を示す。白い棒グラフが重回帰分析，黒い棒グラフが画像回帰 CNN モデルを示している。全体的に画像回帰 CNN モデルは，単回帰分析よりも精度が高かった。特に，着蕾期の 5 月 30 日のモデルでは，画像回帰 CNN モデルが単回帰分析のモデルに対して差が大きくなった。このことから，画像回帰 CNN モデルによる収量予測手法は開花期以前にバレイショの収量を高い精度で予測することができる。臼木らによると，バレイショは一定数の中いも（60g 以上）の塊茎数が確保できる条件で，開花期における速効性肥料の施用でバレイショ収量を改善する可能性があることを報告しており⁶⁷⁾，本手法による収量予測モデルを開花期以前に適用し，開花期に速効性肥料を追肥することで，バレイショの収量を改善できる可能性がある。

同様に前章でのトヨシロの画像と収量を基に作成したデータセットを用いて、同様の CNN を新規に学習、テストした結果を図 4-18~21 に示す。決定係数 R^2 は 5 月 28 日（着蕾期）が 0.88、6 月 14 日（開花期）が 0.94、6 月 26 日が（開花期後期）0.90、7 月 9 日（黄化期）が 0.88 と、画像分類手法を用いた収量予測モデルよりも大幅に精度が向上した。予測結果が 2000 kg/10a 付近に固まっているのは前報におけるトヨシロの収量が 2000 kg/10a に偏っていること、すなわちデータの不均衡が原因である。また、収量は同年の重回帰分析の結果と比較して、開花期以外の時期でも高い精度で予測できた。本手法はトヨシロにおいても男爵薯のモデルと同様に着蕾期での予測精度が高く、着蕾期での収量予測を基に追肥を行うことで収量を改善できる可能性を示している。

以上のことから、Fine tuning と回帰手法を組み合わせた画像回帰 CNN モデルは、バレイショの収量予測に有効である。

第 4 節 摘要

- 1) UAV による空撮画像は、異なる施肥条件での植被の違いを確認できたが、NDVI 値に処理区間差は見られなかった。
- 2) 草丈と分枝数は施肥条件によって差が出る傾向があり、莖数は差が無かった。また、収量は施肥量に比例して増大した。

- 3) CNN を用いた画像の回帰による収量予測モデルでの男爵薯収量の予測値は，決定係数 R^2 が 0.82～0.95 の範囲にあり，単回帰分析よりも精度が高かった。
- 4) CNN を用いた画像の回帰による収量予測モデルでのトヨシロ収量の予測値は，決定係数 R^2 が 0.88～0.94 の範囲にあり，前章の画像分類や重回帰分析を用いた手法よりも精度を改善できた。
- 5) CNN を用いた画像の回帰によるバレイショの収量予測モデルは，各生育ステージで重回帰分析よりも高精度で収量予測できるため，着蕾期や開花期の追肥で収量の改善に繋げることができる。

表 4-1 学習環境

CPU	Core i7-7700
GPU	NVIDIA GeForce GTX 1070
ライブラリ	Keras (ver.2.2.4)

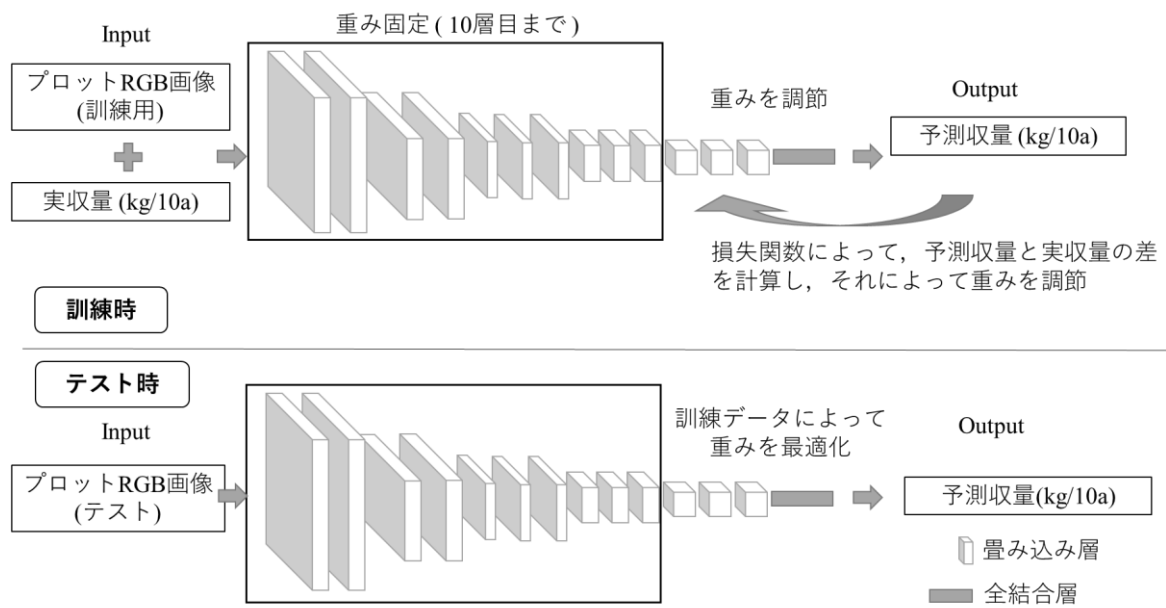


図 4-1 CNN モデルと訓練, テストのフローチャート




図 4-2 各処理区でのプロット RGB 画像の一例（撮影日：6/18）

データセット				
画像データ			ラベルデータ (CSV)	
日付	訓練 (枚)	テスト (枚)	プロット	収量 (kg/10a)
5/30	519	57	A-1	6,429
6/6	259	26	A-2	4,875
6/10	519	57	A-3	6,254
6/13	519	57
6/18	519	57	F-1	2,961
6/20	519	57	F-2	3,096
			F-3	2,426

図 4-3 データセットの構成

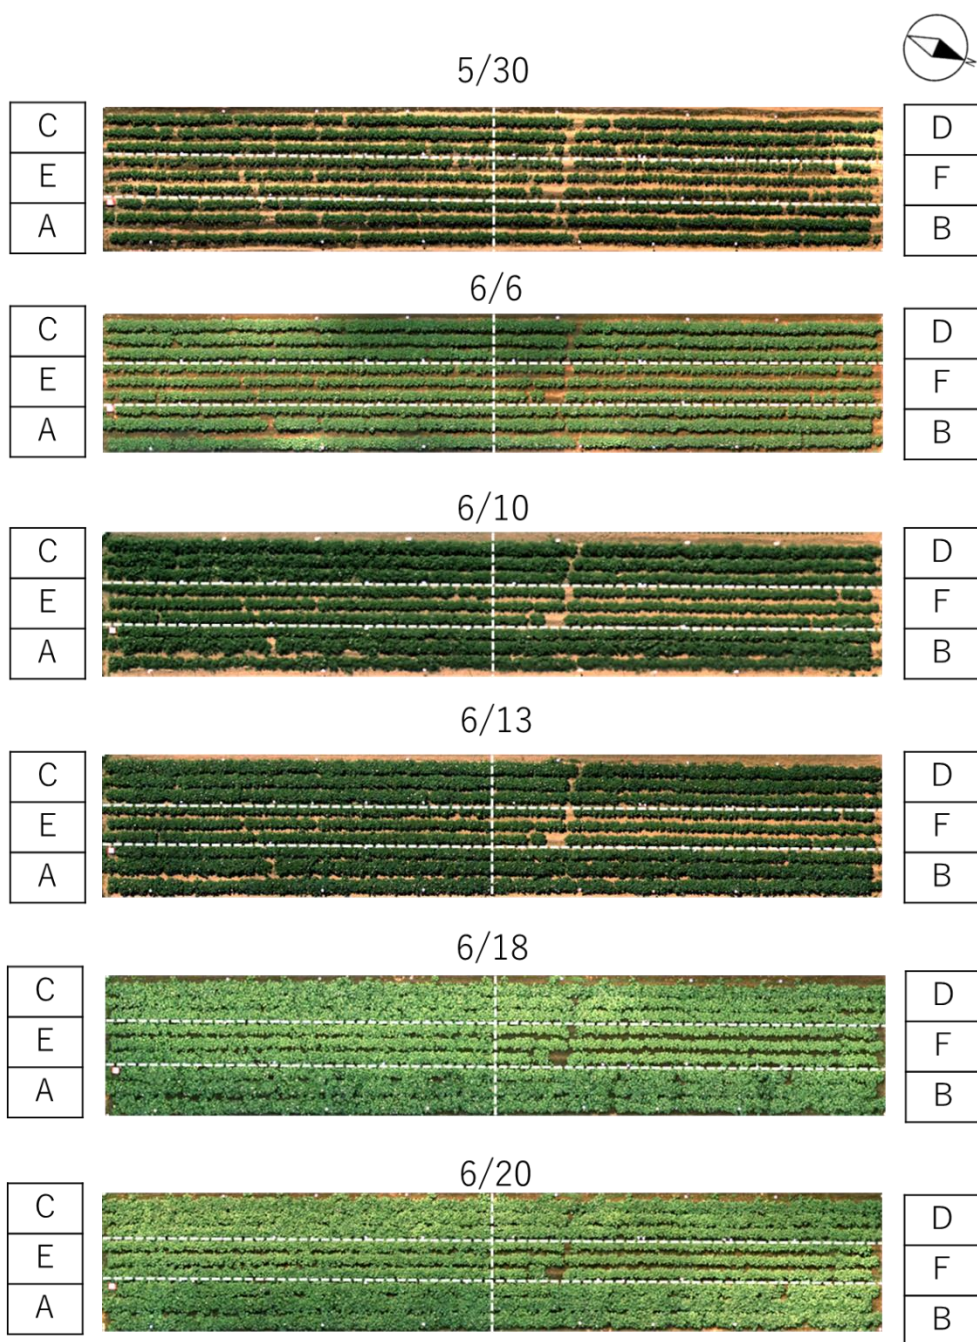


图 4-4 RGB 空撮画像

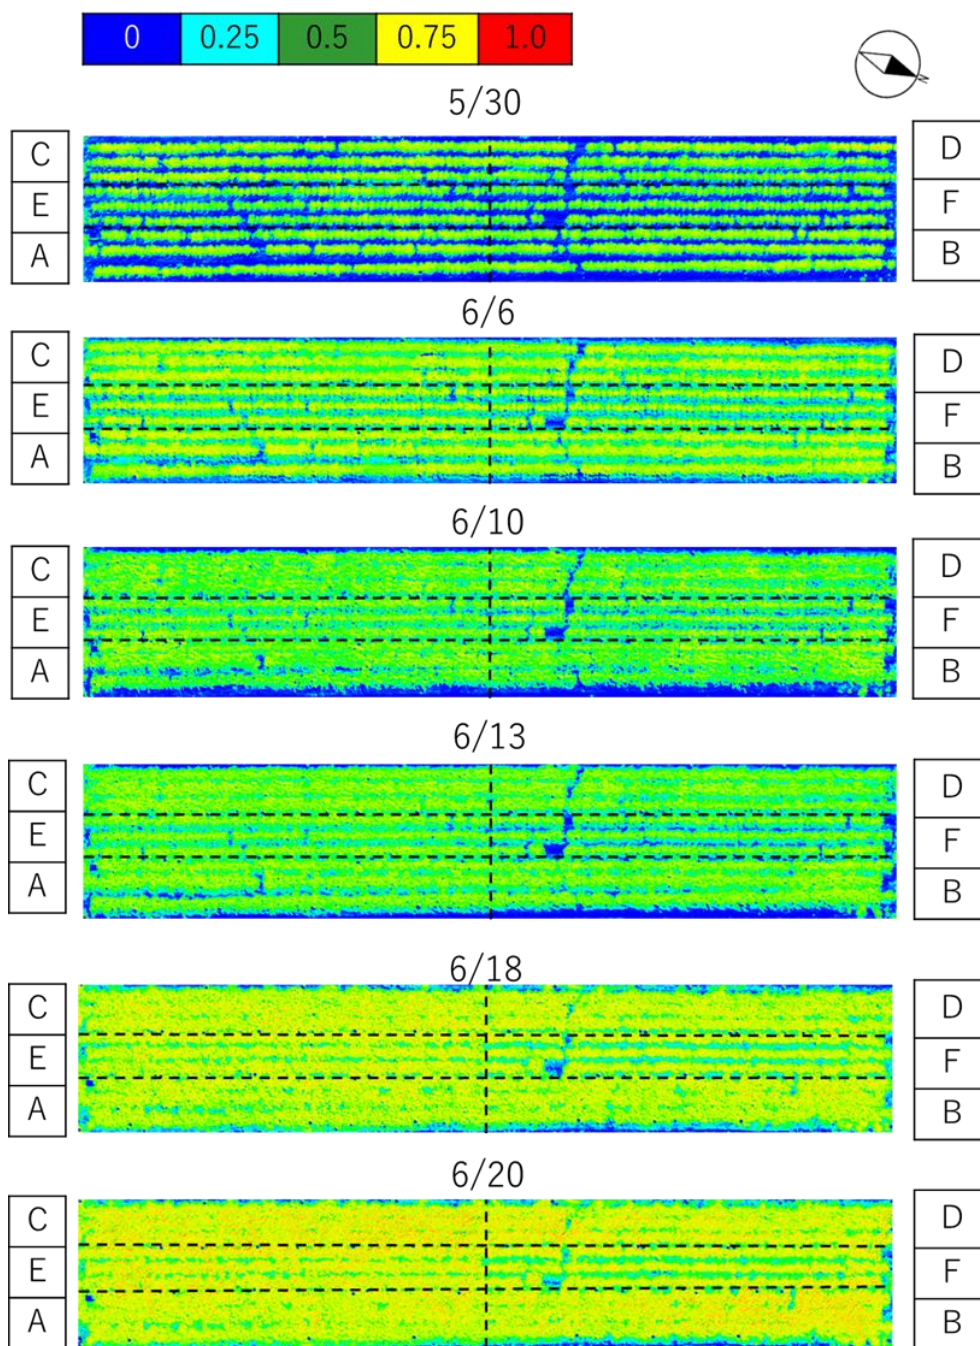


图 4-5 NDVI 空撮画像




図 4-6 NDVI の推移




図 4-7 草丈の推移




図 4-8 各処理区における茎数




図 4-9 各処理区の分枝数 (積算値)

表 4-2 収量調査結果

処理区	収量(kg/10a)	一株当たり塊茎数
A	5853 (851.2)	16 (2.5)
B	5026 (960.2)	14 (1.1)
C	4944 (236.4)	15 (3.8)
D	4111 (186.1)	14 (1.2)
E	3846 (266.7)	15 (1.9)
F	2828 (354.4)	10 (3.8)

注：() 内数値は標準偏差を示す




図 4-10 収量予測モデルの学習の推移 (5/30)




図 4-11 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(5/30)




図 4-12 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(6/6)




図 4-13 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(6/10)




図 4-14 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(6/13)




図 4-15 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(6/18)




図 4-16 CNN の回帰による収量予測モデルでの男爵薯（2019）の予測精度
(6/20)




図 4-17 単回帰分析と CNN モデルの比較




図 4-18 CNN の回帰による収量予測モデルでのトヨシロ (2018) の予測精度 (5/28)




図 4-19 CNN の回帰による収量予測モデルでのトヨシロ (2018) の予測精度 (6/14)




図 4-20 CNN の回帰による収量予測モデルでのトヨシロ (2018) の予測精度 (6/29)




図 4-21 CNN の回帰による収量予測モデルでのトヨシロ (2018) の予測精度 (7/9)

第 V 章 総合考察

第 1 節 モニタリングシステムの選定

モニタリングシステムを構築するには，そのプラットフォームである UAV を用途に合わせて選択することが重要である。現在我が国では DJI 社製品をはじめとし，既製品から産業用途向けの機体まで様々な UAV を購入することができる。そこで，本節では，畑作物生産におけるリモートセンシングで導入が期待できる UAV を検討する。具体的には，実際の農業の現場で使用を検討できる機体をピックアップして比較する。比較する項目は値段，飛行時間，センサの性能，ペイロード，メンテナンス性である。なおここでの比較，選定フローチャートは執筆時（2020年12月時点）でのものであり，今後新機種が登場等によって各機種は更新していく必要があるため，機体選定の際の参考の一つになればと考える。

(1) 機体特性

検討する機体は，以下に示す A～E の 5 機種である。

1) 機種 A：機種 A は，本研究でも使用した大型の産業用マルチコプター（S900，DJI 社，図 5-1，表 5-1）である。これは組み立て式の UAV であり，フライトコントローラーやモーター，ESCなどを自由に選択して構築することができる。本試験ではマルチ

ローター機専用のフライトコントローラー（A2フライトコントローラー，DJI社）を用い，地上局と移動局の通信は映像伝送装置（Light Bridge2）を介して行うような構成とした。モーターはESC内蔵のブラシレスモーターを使用した。カメラを保持するジンバルはミラーレス一眼カメラ用ジンバル（Z-15A7，DJI社）を使用した。

上記のパーツ構成でUAVを自作した場合の金額は，フレーム，フライトコントローラー，ジンバルがセットで¥544,500⁶⁸⁾，映像伝送装置が¥109,900⁶⁹⁾となる。また，センサは¥803,449⁷⁰⁾なので合計¥1,457,849となる。また，上記のUAVを構成するパーツはすべて生産完了品であり，本研究で使用したものと同等なUAVを構築する場合，汎用品パーツで構成する必要がある。

本機体の飛行時間は，6セル12000mAhのリポバッテリーを使用することで約15分の飛行が可能である。これは飛行時の環境（風など）によってある程度増減する。

本機体に取り付けたセンサは，マルチスペクトルカメラ（MicroMCA RGB+3，Tetracam社）である。本センサは解像度が1280×1024のマルチスペクトルカメラで，可視光以外にも近赤外光（720 nm，800 nm）の波長帯もとらえることができる。これによって取得データからNDVIの算出といった，より詳細な解

析ができる。

本機のペイロードは 8.2 kg である。したがって、本機には他のセンサや装置を搭載する余力がある。搭載が考えられる装置としては、RTK-GNSS モジュールや障害物検知用の超音波センサなどである。ただしこれらを搭載する場合は、フライトコントローラーが対応していなければいけないので、フライトコントローラーの換装が必要になる。

本機体は組み立て式の機体であり、飛行前および飛行後の点検、整備が特に重要になる⁷¹⁾。

飛行前の点検としては、①各機器が確実に取り付けられているか、②発動機またはモーターに異音はないか、③機体（プロペラ、フレーム等）に損傷やゆがみはないか、④燃料の搭載量またはバッテリーの充電量は十分か、⑤通信系統、推進系統、電源系統、自動制御系統は正常に作動するかの 5 項目を点検する必要がある。

飛行後には①機体にゴミ等は付着していないか、②各機器は確実に取り付けられているか（ネジ等の脱落やゆるみ等）、③機体（プロペラ、フレーム等）に損傷やゆがみはないか、④各機器の異常な発熱はないかといった点検が必要である。さらに、飛行時間 20 時間ごとに①交換の必要な部品はあるか、②各機器は確実に取り付けられているか（ネジの脱落やゆるみ等）、③機体（プロペラ、フレーム等）に損

傷やゆがみはないか，④通信系統，推進系統，電源系統および自動制御系統は正常に作動するかの点検を実施する必要がある。これは既製品の機体であっても同様に点検する必要がある。

上記の点検時に部品の不調が見られた場合は直ちに交換する必要がある。したがって，実際に運用する場合は，メンテナンス性も重要になる。本機体は前述のとおり 2020 年時点で生産終了したパーツが多数あり，交換用のパーツを購入することが困難な状況にある。例えばフレームパーツを交換する場合は在庫品，プロペラやモーターを交換する場合は同等の性能を持つサードパーティ製のものから選択することになる。そのため，新規に本研究と同等の機体を用いてモニタリングシステムを構築する場合は，別途機種 B を購入することが推奨される⁷²⁾

2) 機種 B: 機種 B は DJI 社から販売されている新型の産業用マルチコプター (M600 Pro, DJI 社, 図 5-2, 表 5-2) である。この機体は S900 とは異なり，すでにメーカーが組み立て済みで出荷しているため，セットアップが容易である。またフライトコントローラーは最新型 (A3, DJI 社)⁷³⁾が搭載されているため，同社の RTK-GNSS モジュール⁷⁴⁾との連携も可能となっており，センチ単位のホバリング，飛行ルートを設定しての自動航行といった高度な飛行を行うことができる。さらに，本機は 6セル 4500

mAh の LiPo バッテリーを 6 個搭載することから飛行時間も大幅に増加しており，カメラ，ジンバルの選択次第で 18 ～ 35 分程度飛行できる。値段は ¥604,890 となっている。また，本機には前記したカメラジンバルシステムが搭載可能で，本研究で利用した空撮システムが構築できる。ペイロードは 15.5 kg となっている。

3)機種 C：機種 C は DJI 社の農業向け小型産業用ドローン（P4-multispectral，DJI 社，図 5-3，表 5-3）である⁷⁵⁾。本機はマルチスペクトルカメラ，日照センサ，RTK-GNSS モジュールを搭載した，高度な農作物モニタリングを可能にする産業用 UAV である。

本機はライセンスと専用のアプリがセットになって約 ¥850,000 ある。さらに，これに専用の RTK 基地局モジュールが付属されて価格が ¥1,200,000 となっている⁷⁶⁾。

バッテリーは 4 セル，15.2V，5870mAh の LiPo バッテリーを使用し，最大で約 27 分間の飛行が可能である。

センサは RGB（可視光），Blue（450 nm ± 16nm），Green（560 nm ± 16 nm），Red（650 nm ± 16nm），Red Edge（730 nm ± 16 nm），NIR（840 nm ± 26 nm）のバンドを捕捉できる 6 つのセンサが一体になったマルチスペクトルカメラを搭載している。各センサ

の解像度は 1600 × 1300 である。

本機のペイロードは 1.5 kg となっており，他の産業用 UAV と異なり追加でセンサーやモジュールを追加することは困難である。

運用する際のメンテナンスは，前述の点検項目を確認することが必要である。特に本機は 4 つのプロペラをもつクアッドコプターであり，飛行中のプロペラ，モーターの故障は墜落につながる。したがって，プロペラおよびモーターの点検は入念に行う必要がある。また，本機を運用する場合は，定期的な交換が必要と考えられるパーツとしてプロペラがある。しかし，本機はもともと主力商品であった機体をメーカーが農業モニタリング向けに改造した機体であるため，本格的な生産が終了した現在でも多くの在庫が確認されている。また，予備のプロペラは互換性のある多くの社外品が存在しており，入手が容易である。

この機種にはそのほかにも様々な特徴がある。本システムにはフライトミッションの計画からデータ取得，マッピングなどの解析などを行う飛行支援ソフトウェア（DJI Terra，DJI 社）と自動航行ソフトウェア（DJI GS Pro，DJI 社）がそれぞれ使用できる。これら二つのソフトウェアを駆使することで，自動航行ミッションの計画から実行，取得した空撮画像のオルソ化や NDVI マッピング等，農業リモー

トセンシングに必要な作業を効率的に実行できる。また、RTK-GNSS 基地局モジュール(DJI 社, D-RTK2)と組み合わせることで cm レベルの精度の位置情報が画像に付与され、高精度なモニタリングが可能である。さらに機体上部には日照センサが設置されており、太陽の放射照度を捉えることで高精度な植生指数データを測定することができる。

4) 機種 D: 機種 D は小型空撮用マルチコプター(Mavic Air 2, DJI 社, 図 5-4, 表 5-4)である。これは、アーム部分を折りたたみ式にすることで携帯性を高めた小型の空撮用マルチコプターである。

本機体は主に一般ユーザーをターゲットとした空撮用マルチコプターである。そのため、値段も ¥105,600⁷⁷⁾と前述の 3 機体よりは安価となっている。

本機体は、3セル、11.55 V、3500 mAh の LiPo バッテリーを使用し、無風条件で最大 34 分間の飛行が可能である。

センサは解像度が 4000×3000 pixel (12 MP) または 8000×6000 pixel (48 MP) の 1/2 インチ CMOS センサを搭載している。後者の解像度はシングルショットのみ対応しているため、本研究のようなタイムラプス撮影の場合は前者の解像度での撮影になる。

本機体を運用する際のメンテナンスについては、これまでの機体と同様に飛行前、飛行後、そして定

期的な点検が必要である。また，予備部品は，2020年5月21日に発売された機体であることから，2020年時点で問題なく行われている。

その他の特徴として，本機体はアームを折りたたみ式とすることで高い携帯性を実現している。機体サイズはアームを展開した状態で全幅が253 mmあるが，折りたたむと97 mmまで小さくなる。このように機体サイズが小さくなることから携行可能であり，運用コストが低い特徴を有する。

しかし，本機体はRTK-GNSSモジュールなどが対応していないため，画像の位置情報はDGPSによるデータになる。したがって，位置情報にはサブメートル範囲の誤差が含まれていることに注意する必要がある。

5) 機種 E: 機種 E は国産の小型産業用マルチコプター（QC730，enRoute社，図5-5，表5-5）である。これはオープンソースのフライトコントローラー（Pixhawk）をベースにした純国産のフライトコントローラー（Ridge Hawk2，アサヒ電子株式会社）を搭載した測量，観測用マルチコプターである^{78) 79)}。

本機体は主にフライトコントローラーの搭載されたGPS自動航行機能による測量で三次元地形モデルの作成を目的とした産業用マルチコプターである。機体価格は¥1,600,000となっている。なお，この価格は機体を持ち運ぶケース，バッテリー，充

電器，地上局用ノート PC，機体の運用に関する講習を含めた金額である。

バッテリーは 2 種類の Lipo バッテリー（355 W，99W）を選択できる。それぞれの飛行時間は約 40 分と 15 分である。前述のセットでは 355W バッテリーが 2 本，もしくは 99W バッテリーが 6 本付属している。なお，メーカーは後者のバッテリーを推奨している。

本機体は，センサとして広角レンズを装備したミラーレス一眼カメラ（Sony，α6000）を搭載している。センサは解像度が 6000×4000 pixel (24 MP) で，機体下部に搭載した防振カメラマウントに固定する。

本機種のパイロードは 6.5 kg となっており，カメラジンバルや画像伝送装置などのオプションを追加で搭載することができる。

本機体のメンテナンスは前述までの点検項目に基づいて行う。本機のプロペラは取り外しができるカーボンプロペラであり，飛行前にモーターの回転方向を確認し確実に取り付ける。その際，オペレーターは，プロペラに損傷やゆがみが無いか等を確認する必要がある。

本機の特徴は，フライトコントローラーにオープンソースの Pixhawk をベースにした国産フライトコントローラー（Ridge Hawk2）を採用している点が挙げられる。このフライトコントローラーは，前述ま

での機体のものと比較して様々な飛行モードを搭載しており，GPSによる位置情報を基にした自動航行やカメラシャッターのトリガー，GPS誘導でなく気圧計のみで高度を保つ実験的な飛行モードなど，多種多様な動作を行うことが可能である。さらに，本機はGPSモジュールをRTK-GNSSモジュールに変更することでRTK-GNSSによる高精度な位置情報の取得，それによる制御がそれぞれ可能になる。

(2) モニタリングシステムの選定

図5-6にモニタリングシステムを構成する機体の選定に関するフローチャートを示す。

ここまで，A～Eの機種について検討してきたが，実際にモニタリングシステムを選定する場合は，対象作目やどの程度の情報が必要か，どのような解析を行いたいかによって機種を選定することになる。すなわち，必要な情報や観測対象の種類・規模，データ品質などを検討し，機体，センサ等を最適化することが必要である。

本研究全体を通して行ったようなNDVIをはじめとした近赤外バンドを用いる一般的な植生指数の算出やマッピングを行う場合は，機種AとBの大型産業用マルチコプターとマルチスペクトルカメラを組み合わせたシステム，もしくは機種Cの小型産業用マルチコプターが必要になる。ただし，植生指数には，可視光画像のみを使用した緑過剰

指標（GEI, Green Excess Index）といったものもあり，植生/非植生の判別への応用が可能であるとされている⁸⁰⁾。このような植生指数は，農作物の肥培管理などの精密さが要求されるタスクに適用可能かどうかを検証する必要があるが，植生の有無などを判別する程度のタスクでは十分に応用が可能である。したがって，植生の確認やほ場全体を空撮画像で確認する目的に限定すれば機種 D，E のマルチコプターでも十分に活用できるといえる。

（3） 空撮データの解析と連動した機種選定

UAV で取得した空撮画像などのデータは，位置情報と関連付けた高度な解析に用いるために，高精度な位置情報を取得および付与することが重要になる。空撮画像の位置情報の正確な取得と付与は，地理情報システム（GIS, Geographic Information System）などを活用した Spatial 解析が可能になる。GIS では，多年度にまたがったデータや異なる地点でのデータ，その他栽培環境に関する変数をレイヤ化して組み合わせることでより複雑な解析が可能になる⁸¹⁾。また，NDVI や植被などの生育データに正確な位置情報が加わることで，それらを基にした栽培管理の自動化，効率化に繋げることができる。例えば，NDVI が低いエリアの位置情報を基に追肥の量を自動調節するシステムと併用することで，高精度な肥培管理技術が

実現できる⁸²⁾。

以上のように，UAVで取得したデータをGISと連動させ，高度な解析や栽培管理技術に応用する場合は，RTK-GNSSモジュールを利用可能な機種A～C，Eのような産業用マルチコプターが有効である。



図 5-1 機種 A : 大型産業用マルチコプター (S900)

表 5-1 機種 A の主要諸元

型式	S900
全長 (mm)	900
全高 (mm)	640
ペイロード (g)	8,200
飛行可能時間	約 10 分



図 5-2 機種 B：新型産業用マルチコプター（M 600 Pro）

表 5-2 機種 B の主要諸元

型式	Matrice 600 Pro
全長 (mm)	1668
全高 (mm)	727
ペイロード (g)	15,500
飛行可能時間	16 分 (ペイロード 6kg 時)



図 5-3 機種 C : 小型産業用マルチコプター (P4-multispectral)

表 5-3 機種 C の主要諸元

型式	P4-multispectral
対角寸法 (mm)	350
ペイロード (g)	1487
飛行可能時間	約 27 分
取得可能バンド	Blue (450 nm \pm 16 nm)
	Green (560 nm \pm 16 nm)
	Red (650 nm \pm 16 nm)
	Red Edge (730 nm \pm 16 nm)
	NIR (840 nm \pm 26 nm)



図 5-4 機種 D : 小型空撮用マルチコプター (Mavic Air)

表 5-4 機種 D の主要諸元

型式	Mavic Air 2
全長 (mm)	183 (展開時)
全高 (mm)	74 (展開時)
ペイロード (g)	570
飛行可能時間	34 分



図 5-5 機種 E : 国産小型産業用マルチコプター (QC730)

表 5-5 機種 E の主要諸元

型式	QC730
全長 (mm)	578
全高 (mm)	255
ペイロード (g)	6,500
飛行可能時間	30 分

表 5-6 UAV の性能比較

	A	B	C	D	E
マルチスペクトルデータの取得	○	○	○	×	×
RTK-GNSS による高精度な位置情報の取得	△	△	○	×	△
CNN を用いた情報解析	○	○	○	○	○
メンテナンス性	×	○	○	○	○

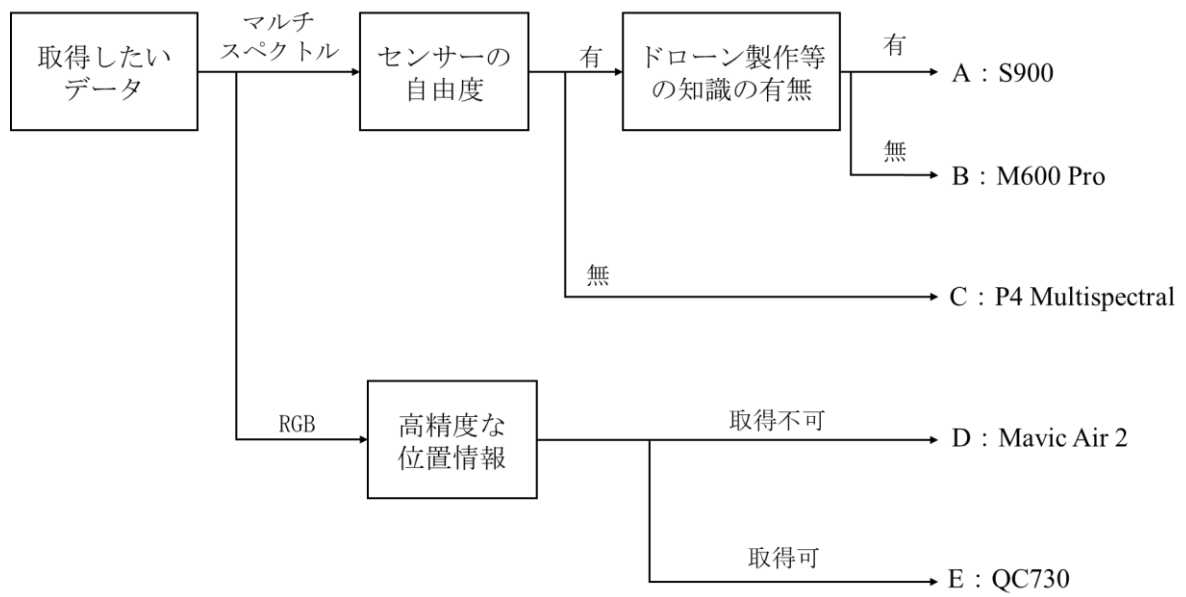


図 5-6 機体選定のフローチャート

第 2 節 露地畑作物栽培での各種 CNN 技術と Fine tuning 技術の展開

(1) 露地畑作物栽培における AI 技術の導入に ついて

CNN 技術は、2014 年ごろから農業分野で使われるようになり、その後徐々にそれを応用した事例が増えてきた。中でも画像認識と物体検出については多くの事例が報告されている⁴³⁾。今後、農業分野では各種センサの小型化、低価格化が進むことで、ほ場内の多種多様な情報が取得できるようになることが予想される。さらに、CNN をはじめとした AI 技術は、通信規格の進化やストレージ容量の増加、計算機の処理能力の向上で膨大なデータが蓄積され、それを解析するためのツールとして導入が加速していくと予想される。本節では、今後導入が期待できる露地畑作物栽培における AI 技術の導入について検討する。

CNN による画像認識分野は、前述のとおり農業分野でも多くの事例が報告されていることから、より多くの応用事例が考えられる。2020 年時点では、すでに画像からの作物種や雑草種、病害の分類などの多くのタスクで利用が報告されている^{83)~86)}。これらのタスクに対しては、我が国でも同様に導入していくことが可能である。特に作物に発生した病害などの同定は防除の観点から重要であり、作物の病害

や雑草の種類を特定して分類する CNN モデルは、病害や雑草種を見分けられない経験の浅い農家に対して推定値を示し、防除などの判断を助ける意思決定支援ツールとなる。また、先行事例では病害のデータをスマートフォンの画像で学習を行っていることから、特別なプラットフォームが要らない点でも実用性が高い。

CNN による画像の回帰は本研究で用いた技術であり、画像からそれに紐づけられた数値を予測するタスクへの適用が期待できる。すなわち、本手法は生育途中の植物体の画像から最終的な収量や収穫物の成分を予測するといったことへの応用が期待できる。成分の予測は、収穫物の成分が重要な場合に有効である。例えばコムギの場合、子実タンパク質含有率は品質評価の上で重要なファクターであり、用途によって要求される子実タンパク質のレベルが異なる⁸⁷⁾。コムギのタンパク質含有率はコムギの窒素栄養状態によって変動するため、コムギ栽培において窒素施肥管理の重要性が高く、CNN の回帰による予測を適用させることで、より高精度な管理が可能になると考えられる。また、この技術の利用は、UAV で撮像した空撮画像から草丈を推定することも可能である。作物の草丈を予測する技術は、高精度な水稻の倒伏予測マップを作成に繋がる。水稻の倒伏被害はコンバインでの収穫作業を困難にし、

ヘッドロスによる収量低下や水分過多による品質低下につながる。倒伏を事前に予測することは、中干やケイ酸資材の投入などの対策を講じることができる。

また、CNNによる物体検出手法は、近年YOLOに代表される物体検出アルゴリズムの登場によって注目を浴びている。物体検出とは入力画像に写っている物体のカテゴリとともに、その物体が写っている場所を四角形で囲む形で出力する手法である。これは画像分類手法よりも場所の推定が必要あること、1枚の画像に複数種類の物体が登場しうる、画像の一部分に小さく写っているものを検出する必要があるなどの理由から難易度の高いアルゴリズムである⁸⁸⁾。農業分野でこのアルゴリズムを応用する場合は、画像に含まれる作物の病虫害などの検出への応用が期待され、実際にこれらのタスクに応用した事例が報告されている。FuentesらはFaster R-CNN, R-FCN, SSDを用いてトマト葉に発生した病害と害虫の検出を行っており、アノテーションした9種類の病害や害虫を効果的に認識できることを示している⁸⁹⁾。OzguvenらはFaster R-CNNを基にしたテンサイにおける褐斑病(*Cercospora beticola*)の検出手法を提案しており、テストの結果全体的な正しい分類率は95.48%であった⁹⁰⁾。

病害検出以外には、ほ場内の雑草検出への利用も

考えられる。AbdulsalamらはYOLO v2を使用してほ場内の4種類の雑草を検出、分類する手法を提案しており、高い精度で雑草の検出および分類を行っている⁹¹⁾。さらに、キャベツをはじめとした結球野菜の生育状況を把握し、ほ場内の結球を検出することにも応用ができる。塚野らは、マルチコプターによるRGB空撮オルソ画像とYOLO v3による物体検出アルゴリズムを組み合わせてキャベツの結球検出モデルを構築しており、キャベツの結球を高い精度で検出できることを示している⁹²⁾。

それ以外にも、ほ場内に設置した監視カメラ映像を使った害獣の検出にも応用が考えられる。シカやイノシシなどの野生鳥獣による農作物被害額は約158億円（平成30年度）にのぼる⁹³⁾。宮下らは画像認識技術による獣害対策の高度化を目的に、フィールドカメラで撮影された野生動物画像を基に合計14,226枚のデータセットを作成して公開している。さらに画像を追加したデータセットによる画像分類では、約80%の認識率を達成している⁹⁴⁾。以上のように、CNNを用いた物体検出手法は、今後も農作物の病害、雑草、収穫物、害獣の検出といった様々なタスクに応用が期待できる。

Fine tuningをはじめとした転移学習手法は、すでに学習済みのモデルを使用して学習をする手法で、少ないデータであっても十分に、かつ短時間でモデ

ルを学習できる。このことから、転移学習手法は多くの事例で使用されており、現在主流となりつつある。露地畑作物栽培では、生育途中のデータから CNN モデルを構築する場合、限られた期間で大量のデータを取得する必要がある。本試験のように、生育途中の画像から CNN による回帰で最終的な収量を予測するタスクに利用する場合は、画像データだけでなく、ラベルデータとなる収量データを収集することにも多くの時間と労力を要する。そのため、Fine tuning 技術はデータ取得に要するコストを抑えられることから有用な手法といえる。これらのことは、物体検出でも同様であり、データ収集およびデータのアノテーション（画像データへのメタデータ付与作業。この場合はオブジェクトの位置を指定すること）の簡略化に寄与できる。

ただし、精度が良好な AI を作成するには、この技術を用いる場合であっても良質なデータをできるだけ大量に蓄積する必要がある。これには用途に合わせたデータをクラウド技術などのデータベースで管理することが有効であり、これを地域レベルで構築することで地域にあったデータの蓄積が可能である。一例として、山形県庄内地域では、水稻やだだちゃ豆といった特産品や、スマートテロワール構想における主要作物であるバレイショなどの生育途中の空撮画像と収量データを地域レベルで蓄

積することで、良質な収量予測モデルや農作物に付加価値を付けて新たなバリューチェーンの構築につなげることができる。また、水稻のいもち病や潮風害などのデータを蓄積することで、これらを検出するモデルを構築して対応策を提案することが可能である。

データベースの構築で課題となる点としては、①蓄積するデータの均質化、②データベースの運用、管理するためのコスト、③データベース内の画像の精査およびアノテーションである。①については、データを収集する人によってデータの質が変わってくることがある。具体的には、画像データの解像度や被写体の位置、大きさなどが人や使用機材によって変化することである。②については、画像のデータを蓄積するクラウドなどのデータベースサーバーやそのデータを守るためのセキュリティ費用などが含まれる。③については、データセット内の画像に不適切な画像がないか等のチェックをする必要がある。画像がぶれていたり、ピントが合っていない画像は、CNNの学習に際して悪影響を及ぼす可能性があるため除外が必要である。さらにアノテーション作業はAI、特に物体検出における教師データ作成に必要な becoming プロセスで、扱うデータが増える分この作業も増えることから時間や労力といったコストが多くなる。

これらの課題には、以下のような対策が考えられる。①については、解像度などの撮影条件をそろえたり、被写体が中央にはっきり写るようにガイドを表示して撮影を行うスマートフォン向けアプリケーションを開発することである。②については、クラウドサーバーなどを維持、管理する枠組みを地域内で構築する必要がある。ビッグデータを扱うためのデータベースに関する先行事例としては、医療画像向けのクラウドデータベースがある。これは2018年から日本医療研究開発機構（AMED）が支援し、国立情報学研究所（NII）や医学系学術団体が連携して運用、管理している⁹⁵⁾。農業においても上記のような体制を地域、ないしは国レベルで構築していく必要がある。③については、データの精査やアノテーションを含むビッグデータの管理を効率よく行う手法を確立する必要がある。特に後者のアノテーションは、現在AIを作成する際の大きなハードルになっている。これには一般的にはクラウドソーシングによる作業が行われている。クラウドソーシングとは、インターネット上で不特定多数の人に仕事を依頼したり、アイデアやデザインを募集したりするWEBサービスの名称である。AI作成の場合では、画像や動画などの基データにアノテーション作業を代行してもらうことになるが、このクラウドソーシングにも問題点はいくつかある。まず、教師デー

タの品質はアノテーションを行うアノテーターによって変動する可能性がある。また，一定の品質を確保するには，時間や費用といったコストの因子が大きくなっていく。そのため，AI技術を普及拡大するには，このアノテーション作業の効率化が必須である。アノテーションの効率化については，これまでいくつかの研究が行われている。Suらはクラウドソーシングにおいて，より効率的で正確な物体検出向けのアノテーション作業の手法を提案している。この手法によって，アノテーションにかかる時間が従来手法と比較して少なくとも32.8%減少し，アノテーション率が97.9%，バウンダリーボックスの正確性が99.2%でアノテーションを行えることを報告している⁹⁶⁾。また，Papadopoulosらは，機械学習を応用してアノテーションを効率化させるフレームワークについて提案している⁹⁷⁾。これらの対策を実施することで，農業向けのデータベースを構築し，実際に利用していくことが可能になる。

(2) AI農業の展開について

前記のようなCNNを基にしたAI技術は，利用できるタスクが限定的である。したがって，今後より複雑なタスクを実行できるAI技術が開発，実装されることが予想される。その背景には小型で高性能かつ安価なコンピュータの登場⁹⁸⁾，センサの低価格化⁹⁹⁾，クラウドなどのストレージの容量増加¹⁰⁰⁾，

通信技術の進化¹⁰¹⁾等がある。さらに、農業の生産現場では、ロボットトラクタやロボットコンバインなどの高度な農業機械の普及¹⁰²⁾やモニタリング、薬剤散布などを目的とした自動航行可能なドローンの規制緩和¹⁰³⁾が進んでいくことから、それらをセンシングデバイスとして複雑で膨大なデータの収集と蓄積が可能になる。そしてそこで得られる多種多様なデータは、AIがこれまで以上に複雑なタスクを実行していくための基盤となる。そこで予想される農業の未来像について検討する（図 5-7）。

未来の農業では、ほ場の土壌温度や pH などの土壌情報や、ロボットでの作業記録、収量データ、ドローンモニタリングによるリアルタイムな栽培環境データ、作物の生育データといった膨大なデータが収集できるようになる。これらのセンサはネットワークによって繋がり、クラウドなどのストレージにデータをアップロードしていく。この膨大で複雑なデータの解析には AI が使用され、生産管理 AI による解析と作業の指示を行うことにより、より精密な栽培管理が可能になっていく。この作業はロボットトラクタ、コンバイン、UAV が行うことで、少ないコストで最大限の収量を達成できるようになり、持続可能な農業の実現にもつながっていく。

さらに ICT によるネットワークのつながりは、生産者側にとどまらず、顧客との結びつきもこれまで

以上に強固になる。ここでも蓄積される販売データの解析には AI が使用される。顧客は欲しい農作物を注文し、それらの注文データを AI が処理していく。ここで得られる顧客のデータや販売データは栽培管理用 AI と販売用 AI の間で共有、処理され、生産者へと届けられる。生産者はその情報を基に農作物を出荷する。顧客への配達は自動運転車や配達用ドローンが行うことで、必要なところに必要な分だけ、ジャストインタイムでの供給が可能になる。

以上のように、農業の ICT 化とそれによって構築される AI 技術は、農業を含めたこれまでの社会を大きく変革していくことが考えられる。また、これらの要素は、農業の 6 次産業化のような総合産業化を促進して地域社会の活性化につながっていく¹⁰⁴⁾。したがって、農業における ICT 化と AI 技術の導入は、今後とも継続して研究していく必要がある。

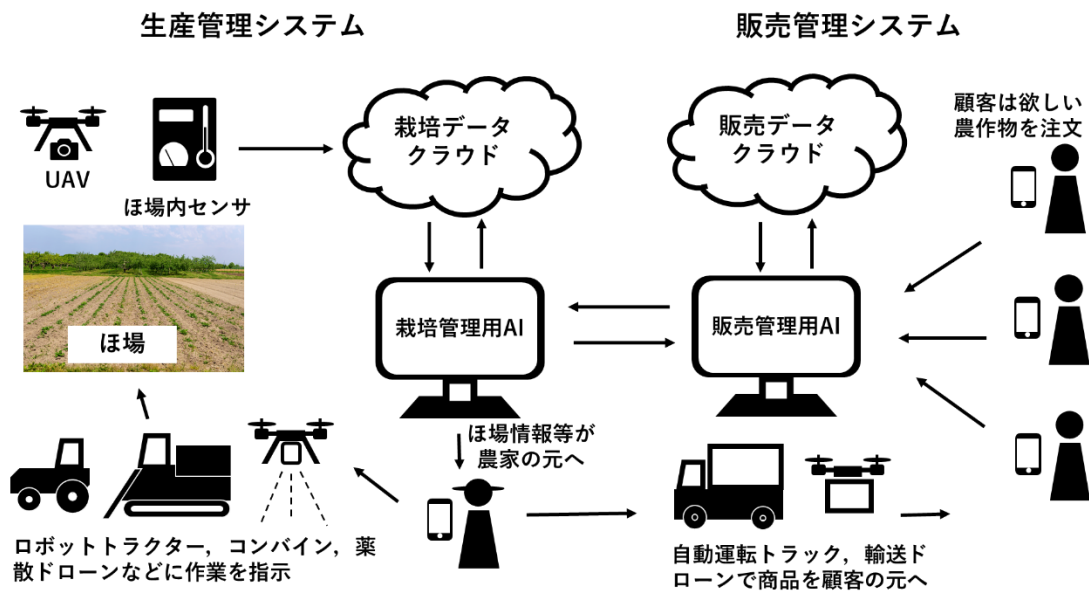


図 5-7 農業の未来像

第 3 節 収量予測システムの社会実装と他作目への展開

本研究で構築した収量予測モデルを社会実装するには、この収量予測モデルで農家に利益をもたらす必要がある。本試験での収量予測モデルの実装で得られる経済的なメリットは、施肥量の最適化によるコスト削減と適正な施肥管理によるバレイショ収量の底上げに繋がり、経験の浅い新規就農者であっても熟練者と同等程度の肥培管理を行うための手助けになる。それは、最終的に生産技術の継承や新規就農者の育成に繋がる。

バレイショ栽培の場合、施肥管理は非常に重要な要素となる。窒素肥料を過剰に投入すれば塊茎の品質低下や倒伏、疫病の罹病を招き¹⁰⁵⁾、逆に施肥が少ない場合は夏疫病などの病害への抵抗性が損なわれる¹⁰⁶⁾。バレイショの施肥基準としては、一般的には成分量で窒素が 8~9 kg/10a、リン酸が 18~20 kg/10a、カリウムが 13~16 kg/10a といわれている¹⁰⁷⁾。この水準での収量を基準に、本試験での施肥設計を考察する。本学の試験での施肥条件は、2018年と2019年試験でのC区の施肥条件（基肥：6 kg-N/10a、追肥：2 kg-N/10a）が基準となる。したがって、A区およびB区では3~4 kg-N/10a分の減肥が可能であり、D~F区では2~6 kg-N/10a分の追肥が必要であるといえる。

減肥によるコストカットについては，A 区の施肥条件で基肥が 10 kg-N/10a，追肥が 2 kg-N/10a なので，基肥を 4 kg-N/10a 分の削減が可能である。本試験で使った基肥は窒素成分で 14% の高度化成肥料（14-14-14）なので，20 kg 袋中に 2.8 kg の窒素を含んでいる。したがって 10 a 当たりでの A 区の基肥は $3.6 \div 4$ 袋，C 区は $2.1 \div 3$ 袋が必要になるので，10a 当たり 1 袋分の削減が可能となる。高度化成肥料 20 kg 袋は 1,430 円（税込，2020 年 8 月現在）¹⁰⁸⁾ なので 10a 当たり 1,430 円のコストダウンが期待できる。同様に B 区は基肥が 4 kg-N/10a の削減が可能で，追肥を 2 kg-N/10a を行う必要がある。基肥は A 区と同量の削減が可能である。追肥は硫安（N:21%，4.2 kg/袋）を使用したもので約 0.5 袋/10a 分必要になる。硫安は 1 袋 920 円（税込，2020 年 8 月現在）¹⁰⁹⁾ であるため，全体で 510 円/10a のコストダウンが見込まれる。

次に収量の底上げによる収益の増加について考察する。D 区の施肥条件は基肥 6 kg-N/10a のみであるので，追肥を行う必要がある。したがって，前述の B 区の想定から，硫安が約 0.5 袋/10a 必要なので，920 円/10a 分コストがかかる。しかし，収量は男爵薯（2019 年）の調査結果から C 区で 4944 kg/10a，D 区で 4111 kg/10a であることから，833 kg/10a 程度の増加が見込まれる。平成 26 年～平成 30 年のバレ

イショ販売価格は全国平均で 107 円/kg であるから¹¹⁰⁾、コストと差し引きで 88,211 円/10a 分の増収が期待できる。E 区の場合は施肥条件が基肥 2 kg-N/10a、追肥 2 kg-N/10a であるので、基肥が 4 kg-N/10a 分の追加が必要になる。したがって 1,430 円/10a 分のコスト増加となる。それに対し、期待できる増収程度は収量調査結果から 1098 kg/10a であるので、コストと差し引きで 116,056 円/10a 分の増収が見込まれる。F 区の場合は、施肥条件が基肥 2 kg-N/10a のみであるので、基肥 4 kg-N/10a、追肥 2 kg-N/10a 分のコスト増が必要である。対して、期待できる増収程度は収量調査結果から 2116 kg/10a 程度なのでコストと差し引きで 224,062 円/10a 分の増収が期待できる。この肥料の追加による増収は、着蕾期における収量予測を適用することで、同一の栽培期間内で達成できる可能性がある。

山形県におけるバレイショ栽培面積は平成 25 年の時点で 239 ha¹¹¹⁾となっている。上述のシミュレーションを山形県の全バレイショ栽培ほ場に適用させた場合、A 区の条件では -3,417,700 円、B 区の条件では -1,218,900 円分のコストカットになり、D 区の条件では +210,824,290 円、E 区の条件では +277,373,840 円、F 区の条件では +535,508,180 円分が増益となり、それぞれ経済効果が期待できる。

しかし、この収量予測システムは、社会実装する

ことを想定した場合に課題もある。まず，収量予測システムの運用には，大量のデータ蓄積が必要不可欠である。CNNはその構造上大量のデータが必要であるため，データの蓄積やデータセットの作成などを効率的に行う必要がある。データの取得については，UAVの自動航行技術を応用することでデータ取得作業を簡略化し，均一なデータを取得することでオルソ化も確実に行うことが可能となる。データの蓄積は農家個人で行うことは難しく，多くの時間を必要とすることが考えられる。また，CNNの汎化性能を高めるためには様々な条件のデータや質の良いデータの取得および蓄積が必要になる。したがって，農家個人ではなく地域レベルでのデータ取得と蓄積するための専門の組織や枠組みが必要だと考えられる。これにはズコーシャ（株）の精密農業事業が参考になる³¹⁾。同社は，北海道において精密農業支援事業を展開しており，データの収集，蓄積，解析を行い，それによって得られた土壌腐植マップ，作物生育状況マップ，過湿ほ場の抽出マップなどを生産者や行政に提供している。このような農業生産に関する情報のプロフェッショナルを地域レベルで育成していく必要がある。そして土壌データや作物の生育データ，ほ場空撮画像データなどを収集し，そのデータをデータベース化して蓄積し，GIS等で解析を行って，作物情報や土壌情報，管理計画を地

域の農家や JA 等に，土壤情報は行政にそれぞれ提供して利活用する。以上のような枠組みを地域で構築することでデータの取得や蓄積に関する課題を解決できる。次に，CNN の構築に係るプログラミング技術のハードルの高さがあげられる。本試験における CNN は Python を用いてコーディングを行っているため，Python の技術が必要になる。したがって，本技術を幅広く普及させるには，使用しやすい UI（ユーザーインターフェース）が必要になる。例えば，本研究で構築したような CNN を用いたバレイショ収量予測モデルをメインのアルゴリズムにし，空撮画像上に収量をメッシュ状にマッピングするようなソフトウェアを開発する必要がある。もしくは，前述の UAV によるデータ収集，解析を行う組織や枠組みで CNN の構築と収量予測を行い，データを提供していくような環境を構築する必要がある。

次に CNN を用いた農作物の収量予測システムの他作目への展開可能性について考察する。今回の実験結果から CNN は施肥条件の違いによる植物体の植被の違いに注目して収量の予測をしている。すなわち，肥培管理や地力の違いで植被に違いが出る作物であれば本技術は適用可能である。そこで，山形県内での主要作物である水稻，ダイズ，コムギについて検討する。

水稻栽培において，安定して高収量を得るために

は追肥等による肥培管理が重要である。一般的に水稻の追肥は草丈，茎数，葉色値といった指標を基に判断する¹¹²⁾。村山らは水稻の籾数が，最高分けつ期の茎数，幼穂形成期の乾物重，窒素含有率といった指標と正の相関があることを示している¹¹³⁾。竹峰らは画像から算出した植被率に基づいた稲体窒素量の推定を行っており，実用上有効な精度で推定できることを示している¹¹⁴⁾。また，浪川らは携帯型 NDVI 測定機で得られた NDVI 値と水稻の窒素吸収量の関係を調査しており，携帯型 NDVI 測定機での NDVI 値で従来手法と比べて同程度の精度で水稻窒素吸収量を推定できることを示している¹¹⁵⁾。以上のことから，リモートセンシングデータから水稻の茎数や窒素吸収量，ひいては水稻収量を予測することが可能といえる。水稻収量を予測するには CNN が有効で，最高分けつ期ないしは幼穂形成期の画像データから収量や窒素含有量などを推定し，それを基に追肥判断などへ応用が可能である。

次にダイズについて検討する。ダイズは現在山形県庄内地域で行われているスマートテロワール構想の中核を担う畑作物である。ダイズは画像解析で群落レベルの植被率の計測が可能であり，草丈，茎径の推定が可能であることが報告されている¹¹⁶⁾。ダイズ（エンレイ）の収量は播種後 50 日の主茎長，節数，分枝数，茎径といった生育量と正の相関があ

り，その中で主茎長は播種後 50 日以前でも収量と正の相関があり，収量を確保するには，播種後 50 日までにダイズの生育量を確保する必要がある¹¹⁷⁾。したがって，本研究での手法は，播種後 50 日までの空撮画像から構築したデータセットを用いることで，植被の違いによるダイズの収量予測が可能である。

また，CNN を用いたダイズの収量予測は，別のアプローチも考えられる。北海道十勝郡において，畑作ほ場の土壌の色を基に地力を推定している事例がある。作付前のほ場を UAV で空撮し，画像中の土壌の赤色域反射率から熱水抽出性窒素を推定し，それを基に作成した土壌肥沃度マップを使用して可変施肥機による高度な肥培管理を行うシステムが実用化されている¹¹⁸⁾。東北地方でのダイズ栽培は主に田畑輪換での栽培が主であるが，水稻とダイズによる田畑輪換で畑の期間が過半を占める場合，土壌の可給態窒素が大きく減耗し，収量の低下を招くとされており，有機質資材による適切な肥培管理が必要である¹¹⁹⁾。これらを踏まえ，ダイズ栽培では播種前に地力を把握し有機質資材の適切な施用を行うことが収量確保に重要であり，これに対して UAV による空撮画像データの活用が考えられる。すなわち，播種前の土壌の空撮画像とダイズ収量データを組み合わせたデータセットを基にした収量予

測モデルを構築することで播種前の土壌画像から高精度な施肥設計を行い，収量確保につなげていくことができる。

コムギは前述のスマートテロワール構想でダイズと並んで重要な畑作物である。コムギは播種時の土壌の乾湿やその後の気温，降水量による生育初期の変動が大きく，生育初期の段階から追肥，除草剤散布，土入れ，踏圧などの中間管理作業を適切に行う必要がある。中でも追肥は収量，品質を向上させるうえで重要で，生育に応じて適した量を散布する必要がある。東北地方におけるコムギの栽培は秋播きが主であり，秋に播種を行い越冬させ，融雪後の茎立期での葉面積の増加と穂数の確保，登熟期における光合成活性の促進を目的に追肥を行う必要がある¹²⁰⁾。ここで追肥量の基準となる指標は茎数であり，単位面積当たりの茎数を基にそれを決定する。森崎らは，UAVリモートセンシング技術を用いてコムギ茎立期における追肥量の診断を行っており，植生指数データを利用することで，実用可能な水準で追肥量を診断できることを示している¹²¹⁾。また，コムギの栄養生長期における植被率は茎数，地上部乾物重と相関があることも報告されており¹²²⁾，UAVとCNNの回帰手法を応用することで，コムギの植被率から追肥量を判断するAIを構築することが可能であり，それによってコムギの中間管理作業を最適

化し，コムギの増収につなげることができる。

さらに，コムギでは収穫物の品質に関して重要な要素に子実タンパク質含有率があり，これによって最終製品への加工適性が決定する¹²³⁾。コムギの子実タンパク質は窒素栄養状態が反映されるため，追肥をはじめとした窒素施肥管理で制御することが可能で，穂孕み期や出穂期，開花期以降の追肥でタンパク含有率を向上させることが報告されている^{124)~126)}。追肥量を最適化するには，子実タンパク質含有率を広い範囲で効率よく推定するための技術の確立が必要である。これまで，人工衛星，UAVを使用したリモートセンシングによってコムギの子実タンパク含有率を推定する事例が報告されている。安積らは，衛星リモートセンシングによって秋まき小麦の子実タンパク含有率の推定および子実タンパク含有率の変動の地図化を試みており，衛星で取得した赤・近赤外域の分光放射輝度およびNDVIと子実タンパク含有率の間に有意な相関があり，収穫時期の3～4週間前以降の衛星データからコムギの子実タンパク含有率が推定でき，それを基に作成した地図によって次年度以降の栽培管理の改善への利用が可能であることを示している²¹⁾。田中らはUAVリモートセンシングと機械学習アルゴリズムを組み合わせたシステムでコムギの収量および子実タンパク質含有率の推定を行っており，マルチスペ

クトルカメラの各波長の反射率を予測変数とするランダムフォレストモデルでコムギのタンパク質含有率を推定できることを示しており，子実タンパク質の予測に機械学習が適していることを示唆している²⁷⁾。したがって，リモートセンシングで得られた出穂後のマルチスペクトルデータおよび植生指数データは，コムギの子実タンパク質を推定することが可能であり，これらをCNNに置き換えることができる。すなわち，子実タンパク質を予測するには，リモートセンシングで得られた出穂期以降のコムギの画像データと子実タンパク質含有率を紐づけたデータセットを基にしたCNNモデルを作成して学習させ，そこで得られる推定結果を基に追肥作業をより精密に行うことができる。

以上のことから，CNNによる収量予測手法は，山形県で現在取り組まれている水稲や畑作物栽培の管理に十分適用できる。ただし，本手法を適用するには，前節で述べたデータの収集，蓄積，最適化を行う枠組みの構築，さらにCNNを運用しやすくするためのUI，迅速なデータ公開手法などの開発が必要である。これらの取り組みを基に開発されるCNNによる収量予測手法は，社会実装の浸透に伴い新規就農者向けの肥培管理の補助や篤農技術の継承と結びつく。さらに，収量予測システムの社会実装は，現在山形県で取り組まれている「スマートテロワー

ル」プロジェクトをはじめとした地域循環型社会の形成を後押しし、肥培管理の最適化による経済効果やデータ運用に関する新たな雇用の創出によって地域経済を刺激することで、今後の地域活性化の一助になるといえる。

第 VI 章 結論

本研究では，UAV とマルチスペクトルカメラを基にしたリモートセンシングシステムを構築し，それによって得られた生育期間中のセンシングデータと収量データから，バレイショの収量を予測するための CNN モデルを構築し，精度を評価した。以上の各研究によって得られた結論を以下に示す。

1. UAV とマルチスペクトルカメラを組み合わせたモニタリングシステムを構築し，バレイショ栽培におけるセンシングを行うことで以下の結論を得た。

(1) 空撮 NDVI 画像から，萌芽の進行や生育に伴う植被の増大，開花の度合いといったバレイショ生育段階の違いや，黄化期における二次成長の発生を確認できた。

(2) 空撮画像から算出した NDVI 値と SPAD 値は黄化によって生育の後半で減少し，両者に相関が見られた。また，二次生長によって NDVI にばらつきも見られ，本モニタリングシステムがバレイショ地上部のクロロフィル量を推定することに使用できることが分かった。

(3) 各プロットの平均収量は規格内品が 2863 kg/10a，規格外品が 1984 kg/10a となった。また，バレイショの収量は開花期の NDVI 値と負の相関

($R^2 = 0.52$) が見られた。

(4) 開発したモニタリングシステムは，バレイショ栽培におけるセンシングデバイスとして有用である。

2. 施肥条件を6段階に設定したバレイショほ場で栽培試験を行い，UAVで取得した空撮画像情報と収量データから，CNNを用いた画像の分類による収量予測モデルの構築と精度評価を行った。その結果，以下のことが明らかになった。

(1) モニタリングシステムを用いたバレイショほ場のセンシングでは，施肥条件の違いによる萌芽の進行や植被の違いが明瞭であったが，NDVI値は処理区間に差がなかった。

(2) 加工用バレイショの草丈，全重，植物体乾物重は施肥量に比例して増大する傾向があった。これらの調査項目とNDVIは決定係数 R^2 が0.58, 0.24, 0.41で相関が見られた。

(3) 加工用バレイショの収量は，A区が4230 kg/10a, B区が4230 kg/10a, C区が2543 kg/10a, D区が2913 kg/10a, E区が2936 kg/10a, F区が2061 kg/10aで、施肥量に比例しなかった。

(4) 加工用バレイショの収量予測では，生育期と開花期の草丈とNDVI値を説明変数，収量を目的変数とした重回帰分析で生育期，開花期のデータを

基にすることで高い精度で予測できた。

- (5) CNNによる収量予測モデルは，データセットのクラス間でのサンプルの不均衡や過学習によって予測精度が低かった。精度の良好な学習を行うためには，クラスごとのサンプル数をそろえる，転移学習によるCNN自体の改善などが必要である。

3. 前項と同様の栽培試験を行い，UAVで取得した空撮画像情報と収量データから，CNNを用いた画像の回帰による収量予測モデルの構築と精度評価を行った。その結果，以下のことが明らかになった。

- (1) モニタリングシステムによる空撮画像は，異なる施肥条件での植被の違いを確認できたが，NDVI値に処理区間差は見られなかった。
- (2) 草丈，分枝数は施肥条件によって差が生じたが，茎数はそれに影響しなかった。また，収量は施肥量に比例して増大した。
- (3) CNNを用いた画像の回帰による収量予測モデルでの男爵薯収量の予測値は，決定係数 R^2 が 0.82～0.95 の範囲にあり，単回帰分析よりも精度が高かった。
- (4) CNNを用いた画像の回帰による収量予測モデルでのトヨシロ収量の予測値は，決定係数 R^2 が

0.88～0.94の範囲にあり，前章の画像分類や重回帰分析を用いた手法よりも精度を改善できた。

- (5) CNNを用いた画像の回帰によるバレイショの収量予測モデルは，各生育ステージで重回帰分析よりも高精度で収量を予測できるため，着蕾期や開花期の追肥で収量の改善に繋げることができる。

謝 辞

本研究を行うにあたり，山形大学農学部の片平光彦教授には終始懇篤な指導や論文の校閲，多大な援助を賜った。また，同大学の小林隆准教授，中坪あゆみ助教には研究や論文に関する指導，助言をいただき，機材や種芋を提供していただいた。ここに謹んで感謝の意を表す。

栽培試験を行うにあたり，山形大学農学部附属やまがたフィールド科学センターの本間英治様，有賀和裕様，佐久間拓也様には，ほ場の耕うんや定植作業，収穫作業といった管理作業を支援していただいた。また，中間管理作業や調査の協力をしてくださった山形大学農学部生産機械学研究室の諸氏に感謝申し上げる。

なお，研究に対し多くの助言を頂いた弘前大学農学生命科学部の張樹槐教授，岩手大学農学部の折笠貴寛准教授に厚く感謝の意を示す。また，論文投稿に際して英文校閲をしてくださった山形大学農学部のロペス・ラリー教授に御礼申し上げます。

末筆ながら，博士課程への進学に当たって多くの理解と援助を頂いた両親と，支えてくださいました婚約者の坂本彩子さんに深く感謝の意を示す。

参考資料

- 1) 農林水産省，2015. 山形県年齢別農業就業人口．
農林業センサス，<http://www.maff.go.jp/j/tokei/census/afc/2015/dailkan.html>， Accessed Mar. 28, 2019.
- 2) 山形県耕作放棄地対策協議会，2015. 耕作放棄地解消の山形県内実践事例集，<https://www.pref.yamagata.jp/ou/norinsuisan/140017/publicfolder201704288913081164/301080154f5c653e68c4573089e36d883011770c51854e8b4f8b96c6.pdf>， Accessed Mar. 28, 2019.
- 3) 農林水産省，2019. 「スマート農業技術の開発・実証プロジェクト」及び「スマート農業加速化実証プロジェクト」について，http://www.affrc.maff.go.jp/docs/smart_agri_pro/smart_agri_pro.htm， Accessed Aug. 9, 2019.
- 4) 農林水産省，2007-2016. 作況調査，作物統計，http://www.maff.go.jp/j/tokei/kouhyou/sAkumotu/sakkyou_yasai/index.html， Accessed June 25, 2019.
- 5) 松尾雅彦，2014. スマート・テロワール 農村消滅論からの大転換（第1版）．学芸出版社，京都，52.
- 6) 松尾雅彦，2017. 「スマート・テロワール」ついに幕開け．農業ビジネス，<https://agribiz.jp/item/d>

etail/4558, Accessed June. 25, 2019.

- 7) 今村奈良臣, 2012. 農業の6次産業化の理論と実践の課題, ARDEC: world agriculture now, (47), 2-6.
- 8) 安岡澄人, 2017. スマート農業の推進. 日本ロボット学会誌, 35巻5号, 362-365.
- 9) 脇山恭行, 井上君夫, 中園江, 2003. 水稻の登熟期における衛星データおよびアメダスデータを用いた収量予測法. 農業気象, 59巻4号, 277-286.
- 10) 境谷栄二, 木村利行, 井上吉雄, 2012. 津軽中央地域における胴割れ米の発生要因の解析, 日本作物学会講演会要旨集, 233, 290.
- 11) 井上吉雄, 横山正樹, 2017. ドローンリモートセンシングによる作物・農地診断情報計測とそのスマート農業への応用. 日本リモートセンシング学会誌, 37巻3号, 224-235.
- 12) 濱侃, 田中圭, 望月篤, 鶴岡康夫, 近藤昭彦, 2018. UAVリモートセンシングおよび登熟期の気象データに基づく玄米タンパク含有率推定. 日本リモートセンシング学会誌, 38巻1号, 35-43.
- 13) 山本修平, 本間香貴, 橋本直之, 牧雅康, 2019. UAVリモートセンシングに基づく農家ほ場におけるダイズ湿害の評価—2017年仙台沿岸部における観測例—. 日本作物学会紀事, 88巻1号, 48

-49.

- 14) 松尾豊, 2014. Deep Learning. 情報・システム
ソサイエティ誌, 19巻, 1号, 12-13.
- 15) Yaping, C., Kaiyu, G., Jian, P., Shaowen, W.,
Christopher, S., Brian, W., Zhan, L., 2018.
A high-performance and in-season classificatio
n system of field-level crop types using time-s
eries Landsat data and machine learning approa
ch. Remote Sensing of Environment, 210, 35-47.
- 16) Jin, G., Hyenjoon, M., Jin, T.K., Syed, I.H.,
Minh, D., O, N.L., Han, Y.P., 2017. Deep convo
lutional neural network for classifying Fusarium
wilt of radish from unmanned aerial vehicles.
Journal of applied Remote Sensing, 11(4), 04
2621.
- 17) 串田圭司, 吉野邦彦, 山路永司, 田渕俊雄, 19
95, 生育段階および品種を考慮した衛星リモート
センシングによる水稻単位収量推定に関する研
究, 農業土木学会論文集, 176巻, 105-112.
- 18) 池田順一, 奥野林太郎, 山縣真人, 2001, 高解
像度衛星 IKONOS の画像データによるコムギ収量
の予測, 日本土壌肥料学雑誌, 72巻, 6号, 786-
789.
- 19) 農文協, 転作全書 1 ムギ, 社団法人農村漁村
文化協会, 東京, 62

- 20) 農文協，転作全書 1 ムギ，社団法人農村漁村文化協会，東京，72
- 21) 安積大治，林哲央，志賀弘行，2006，衛星リモートセンシングによる秋まき小麦子実タンパク含有率の推定技術，日本土壌肥料学会雑誌，77巻3号，317-320
- 22) 秋元侃，安田嘉純，江森康文，深山一弥，1985，リモート・センシングによる草地の診断：2. ランドサット MSS データによる 1 番草収量の推定，日本草地学会誌，31巻，1号，97-103
- 23) 井上吉雄，ギャッシュディンミア，境谷栄治，中野憲司，川村健介，2008. ハイパースペクトル計測に基づく正規化分光反射指数 NDSI マップおよび波長選択型 PLS による植物・生態系変量の評価—米粒タンパク含有率・クロロフィル濃度・バイオマス評価を事例として—，日本リモートセンシング学会誌，28(4)，317-330.
- 24) 小田川信哉，小杉幸夫，齋藤元也，宇都有昭，佐々木由佳，小田久二夫，加藤雅胤，2012，航空機ハイパースペクトルデータを用いた水稻の生育・収量・タンパク含有率の推定手法の開発，写真とリモートセンシング，51巻，5号，270-284
- 25) 中坪あゆみ，田中勝千，杉浦俊弘，加藤亘，三谷歩，石岡義則，嶋栄吉，嶋田浩，2011，航空機ハイパースペクトルセンサを用いた飼料

- 用トウモロコシ (*Zea mays* L.)畑の植生指数と生育量との関係，日本草地学会誌，57巻，1号，34-38.
- 26) 濱侃，田中圭，望月篤，新井弘幸，平田俊之，八幡竜也，鶴岡康夫，近藤昭彦，2018，UAVリモートセンシングおよび日射量を用いた水稻の草丈と収量の推定，水文・水資源学会誌，31巻，2号，68-82.
- 27) 田中貴，周鑫斌，松井勤，2020. UAVリモートセンシングと機械学習による小麦の収量および子実タンパク質含有率の推定，日本作物学会第249回公演会要旨集，72
- 28) 横堀潤，丹羽勝久，清野伸孝，野口伸，2005. ヘリコプターベースリモートセンシングを利用した馬鈴薯生育のばらつきの解析と対策．農業情報研究，14(1)，1-10.
- 29) 辻博之，杉浦綾，2014. UAVを用いた植被率調査から推定したバレイショの受光日射量と収量との関係．第238回日本作物学会講演会要旨集，日本作物学会，30.
- 30) Gómez, D., Salvador, P., Sanz, J., Casanova, J. L., 2019. Potato yield prediction using machine learning techniques and sentinel 2 data, *Remote Sensing*, 11(15), 1745.
- 31) 株式会社ズコーシャ，精密農業，<https://zukos>

- ha.co.jp/business/bs_02/bs_0205/, Accessed January 15, 2021.
- 32) SMART AGRI, 衛星画像解析による野菜の収穫予測サービス「DATAFLUCT agri.」が2020年2月よりスタート, <https://smartagri-jp.com/news/985>、Accessed January 15, 2021.
- 33) Jones, H. G., Vaughan, R. A., 2010. Remote Sensing of Vegetation, Oxford university press, New York, 214-216 (訳書: 久米篤, 大政謙次 (監訳), 植生のリモートセンシング, 2013, 森北出版, 東京)
- 34) 農業・3食品産業技術総合研究機構 生物系特定産業技術研究支援センター, 2011. 作物生育情報測定装置による水稲生育診断のための [利用マニュアル]
- 35) 安積大治, 林哲央, 志賀弘行, 2006. 衛星観測 NDVI による秋まき小麦子実タンパク含有率地図の作成手法, システム農学, 22 (2), 89-98.
- 36) 株式会社ビジョンテック, microMCA シリーズ, http://www.vti.co.jp/inst_MicroMCA.html. Accessed October 6, 2020.
- 37) DJI, ZENMUSE Z15-A7, <https://www.dji.com/jp/zenmuse-z15-a7/info#specs>, Accessed October 6, 2020.
- 38) 岩間和人, 2011, 北海道におけるばれいしょ栽培

- 培技術の新展開， https://www.alic.go.jp/johod/joho08_000089.html, Accessed October 6, 2020.
- 39) 田口啓作，村山大記，1977，馬鈴薯，グリーンダイセン普及会，165
- 40) 気象庁，気象データ， http://www.data.jma.go.jp/obd/stats/etrn/view/monthly_a1.php?prec_no=35&block_no=0263&year=2017&month=6&day=&view=g_, Accessed October 6, 2020.
- 41) コニカミノルタ，SPAD-502Plus， <https://www.konicaminolta.jp/instruments/products/color/chlorophyll/index.html>, Accessed October 6, 2020.
- 42) 田口啓作，村山大記，1977，馬鈴薯，グリーンダイセン普及会，108-110
- 43) Kamlaris, A., Prenafeta-Boldú, F. X., 2018. A review of the use of convolutional neural networks in agriculture, *The Journal of Agricultural Science*, 156(3), 312-322.
- 44) 朝田諒，飯田訓久，村主勝彦，増田良平，2019. ロボットコンバインのためのステレオカメラを用いた物体検出および衝突回避．農業食料工学会誌，81(6)，392-402.
- 45) Patterson, J., Gibson, A., 2019. 詳説 Deep Learning—実務者のためのアプローチ，株式会社オライリー・ジャパン，東京，319. (監訳：本橋和貴，訳：牧野聡，新郷美紀)

- 46) 渡辺和之, 1978. バレイシヨの群落構造と乾物生産特性(第1報), 日作東北支部報, 21, 77-78.
- 47) 吉田稔, 1970. ばれいしよの生理生態学的研究(第6報)花房分化について, 北海道大学農学部邦文紀要, 7(4), 529-538.
- 48) 田口啓作, 吉田稔, 中世古公男, 由田宏一, 1969, ばれいしよの生理生態学的研究: 第2報, 北海道大学農学部附属農場報告, 17, 33-41.
- 49) Baret, F., Guyot, G., 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2-3), 161-173.
- 50) 谷口健雄, 1992, 加工用バレイシヨの肥培管理と品質. 日本土壌肥料学雑誌, 63(6), 723-727.
- 51) Krawczyk, B., 2016. Learning from imbalance d data: Open challenges and future directions. *Progress in Artificial Intelligence*, 5(4), 221-232.
- 52) Pan, S.J., Yang, Q., 2010. A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345-1359.
- 53) 中山英樹, 2015, 深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習. 電子情報通信学会音声研究会, http://www.nlab.ci.i.u-tokyo.ac.jp/pdf/CNN_survey.pdf. Accessed Mar.

28, 2019.

- 54) 田邊大, 市浦茂, 中坪あゆみ, 小林隆, 片平光彦, 2020. 無人航空機 (UAV) と人工知能 (AI) を利用したバレイショの収量予測のためのモニタリングシステムの開発 (第1報), 農業食料工学会誌, 82(4), 339-346.
- 55) Niu, Z., Zhou, M., Wang, L., Gao, X., Hua, G., 2016. Ordinal Regression with Multiple Output CNN for Age Estimation. Proceedings of the IEEE conference on computer vision and pattern recognition, 4920-4928.
- 56) 會下拓実, 柳井啓司, 2017. 食事画像カロリー量推定における回帰による手法と検索による手法の比較. 研究報告コンピュータビジョンとイメージメディア (CVIM). 2017-CVIM-208(32), 1-6.
- 57) Lee, H., Grosse, R., Ranganath, R., Ng, A. Y., 2009. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations, Proceedings of the 26th Annual International Conference on Machine Learning, 609-616.
- 58) 国分牧衛, 朝日幸光, 1983. 施肥量がバレイショ品種の乾物生産と分配に及ぼす影響, 東北農業研究, 33, 93-94.
- 59) 中潤三郎, 玉木秩, 1956. 馬鈴薯に関する生理,

- 生態学的研究（第7報），香川県立農科大学学術報告，7(3)，225-230.
- 60) Hunt, E. R., Jr., Horneck, D. A., Spinelli, C. B., Turner, R. W., Bruce, A. E., Gadler, D. J., Brungardt, J. J., Hamm, P. B., 2018. Monitoring nitrogen status of potatoes using small unmanned aerial vehicles, *Precision Agriculture*, 19(1), 314-333.
- 61) 田口啓作，1957. 馬鈴薯品種の交雑育種に関する研究，東北農業試験場研究報告，12，1-204
- 62) 大崎満，相良和彦，田中明，1992. バレイショの各器官の生長におよぼす窒素施与の影響，日本土壤肥料学雑誌，63(1)，46-52.
- 63) 宗友義美，佐藤和正，黒田俊郎，1981. 春作バレイショの施肥量試験．岡山農大農場報告，4，48-51.
- 64) 吉田稔，中世古公男，1971. バレイショの生理生態学的研究：第7報 塊茎数・塊茎重および塊茎比重の推移について，北海道大学農学部邦文紀要，8(1)，49-59.
- 65) 君島崇，田中明，1981. バレイショにおける塊茎の sink 能，日本土壤肥料学雑誌，52(5)，408-412.
- 66) 農林水産省，2018. 作況調査,作物統計,<https://www.maff.go.jp/j/tokei/kouhyou/sakumotu/sakkyou>

- _yasai/index.html, Accessed Mar. 12, 2020.
- 67) 白木一英, 津田昌吾, 根本英子, 辻博之, 2015.
窒素分施がバレイショの葉色および収量に及ぼす影響. 日本作物学会講演会要旨集, 239, 166.
- 68) 飯塚モデルオンラインショップ, <http://iizukamodel.com/?pid=92494854>, Accessed 12 November 2020.
- 69) エアステージ, https://www.rc-airstage.com/product_info.php/cPath/562/products_id/11943, Accessed 12 November 2020.
- 70) Tetracam, <http://www.tetracam.com/Products-RGB+3.htm>, Accessed 12 November 2020.
- 71) 国土交通省, 無人航空機飛行マニュアル, 2020. <https://www.mlit.go.jp/common/001218180.pdf>, Accessed 12 November 2020.
- 72) DJI, Matrice600 PRO, <https://www.dji.com/jp/matrice600-pro/info#specs>, Accessed 12 November 2020.
- 73) DJI, A3 シリーズフライトコントローラー, <https://www.dji.com/jp/a3?site=brandsite&from=nav>, Accessed 12 November 2020.
- 74) DJI, D-RTK GNSS, https://www.dji.com/jp/d-rtk?site=brandsite&from=insite_search, Accessed 12 November 2020.
- 75) DJI, P4-multispectral, <https://www.dji.com/jp/>

- p4-multispectral, Accessed 12 November 2020.
- 76) Drone, DJI、精密農業・土地管理用ドローン「P4 MULTISPECTRAL」発表 [AIRWORKS 2019], 2019. <https://www.drone.jp/news/20190925152055.html>, Accessed 12 November 2020.
- 77) DJI store, Mavic Air 2, <https://store.dji.com/jp/product/mavic-air-2?vid=91071>, Accessed 12 November 2020.
- 78) 有限会社シンエイ測器, UAV 撮影業者の紹介及びシステム販売, http://www.sineisokki.mie.jp/images/index/QC730_UAV_SURVEY.pdf, Accessed 12 November 2020.
- 79) アサヒ電子株式会社, 事業概要, ドローン用日本国産フライトコントローラー「Ridge Hawk 2」, https://www.asahi-gp.co.jp/denshi/business.html#target_Drone, Accessed 12 November 2020.
- 80) 尾崎敬二, 小型無人航空機搭載デジタルカメラによる単一空撮可視光画像から推定する植生指数, 2018. 日本画像学会誌, 57 巻, 3 号, 302-307.
- 81) 境谷栄二, 井上吉雄, 米の適期収穫への航空機および衛星リモートセンシングの実践的利用, 2016. 日本リモートセンシング学会, 33 巻, 3 号, 185-199.
- 82) 片桐哲也, 安藤和登, 松本由美, 森静香, 藤井

- 弘志，ドローンによる圃場生育評価と無人ヘリによる可変施肥システムを利用した水稻の収量・品質改善について，2016. 計測と制御，55巻，9号，806-809.
- 83) Kussul, N., Lavreniuk, M., Skakun, S., Shelestov, A., 2017, Deep Learning classification of land cover and crop types using remote sensing data, IEEE Geoscience and Remote Sensing Letters, 14, 778-782.
- 84) Reyes, A. K., Caiced, J. C., Camargo, J. E., 2015. Fine-tuning deep convolutional networks for plant recognition, CLFE (Working Notes), 1391, 467-475.
- 85) Dyrmann, M., Karstoft, H., Midtiby, H. S., 2016. Plant species classification using deep convolutional neural network, Biosystems Engineering, 151, 72-80.
- 86) Sladojevic S., Arsenovic, M., Anderla, A., Culibrk, D., Stefanovic, D., 2016. Deep neural networks based recognition of plant diseases by leaf image classification, Computational Intelligence and Neuroscience, 3289801.
- 87) 島崎由美，2011，農作業便利帖 麦・大豆 麦編 ランク区分 コムギ，<https://www.jeinou.com/benri/wheat/2011/01/070935.html> accessed Octob

- er 2, 2020.
- 88) 藤原弘将, 2019. ディープラーニングによる一般物体認識とそのビジネス応用, 画像ラボ, 01, 57-67.
- 89) Fuentes, A., Yoon, S., Kim, S. C., Park, D. S., 2017. A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition, Sensors, 17(9), 2022.
- 90) Ozguven, M. M., Adem, K., 2019, Automatic detection and classification of leaf spot disease in sugar beet using deep learning algorithms. Physica A: Statistical Mechanics and its Applications, 535(1), 122537.
- 91) Abdulsalam, M., Aouf, N., 2020. Deep Weed Detector/Classifier Network for Precision Agriculture, 2020 28th Mediterranean Conference on Control and Automation (MED), IEEE, 2020.
- 92) 塚野正洋, 柿崎理央, 上野美咲, 斎藤雅憲, 武田純一, 小出章二, 庄野浩資, 折笠貴寛, 2019. 深層学習を用いたキャベツの結球検出, 農業食料工学会東北支部報, 66号, 5-8.
- 93) 農水省, 2018. 全国の野生鳥獣による農作物被害状況について. <https://www.maff.go.jp/j/press/nousin/tyozyu/191016.html>, Accessed October 29, 2020.

- 94) 宮下 洸大, 初田 慎弥, 孟林, 泉知論, 2019. 野生動物自動認識のためのデータベース構築と深層学習の試行. 画像電子学会第288回研究会講演予稿.
- 95) 大竹 義人, 日朝 祐太, 高尾 正樹, 菅野 伸彦, 佐藤 嘉伸, 2019. 大規模 CT 画像データベースの AI 画像解析による筋骨格解剖の理解と手術支援システムへの応用, *Medical Imaging Technology*, 37 (2), 89-94.
- 96) Su, H., Deng, J., Li, F. F., 2012. Crowdsourcing Annotations for Visual Object Detection, *Workshops at the Twenty-Sixth AAAI Conference on Artificial Intelligence*.
- 97) Papadopoulos, D. P., Uijlings, J. R., Keller, F., Ferrari, V. 2016. We don't need no bounding-boxes: Training object class detectors using only human verification, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 854-863.
- 98) 矢野 和夫, 2007. センサは Web を超える 省力化から知覚化へ, *情報処理*, 48 (2), 160-170.
- 99) アグリジャーナル, 2020. 低価格の土壌の見える化システムが登場! 購入型クラウドファンディングで, <https://agrijournal.jp/renewableenergy/50006/>, Accessed November 18, 2020.

- 100) 福田 治夫, 天笠 俊之, 2011. 特集 クラウドを支えるデータストレージ技術, 情報処理, 52 (6).
- 101) ソフトバンク, 5Gを実現するネットワーク技術, <https://www.softbank.jp/mobile/network/service/5g/>, Accessed November 18, 2020.
- 102) ロボット農機, 2018. いよいよ本格実用機に! クボタが描くスマート農業の未来と現状, アグリビジネス最前線, <https://special.nikkeibp.co.jp/NBO/businessfarm/agribusiness/07/?P=1>, Accessed November 18, 2020.
- 103) 株式会社旭テクノロジー, 2020. ドローンによる農薬散布方法が変わる! 農業用ドローンの自動航行(自動運転)で実現できること, <https://atcl-dsj.com/work/autonavigation-of-agriculture-drone/>, Accessed November 18, 2020.
- 104) 窪田 新之助, 2017. 日本発「ロボット AI 農業」のすごい未来 2020年に激変する国土・GDP・生活, 講談社, 東京都, 25-34.
- 105) 岡啓, 1969, 十勝地方におけるばれいしよの生産性向上に関する研究 第2報 燐酸多施条件下におけるN用量とばれいしよの生育反応, 北海道農業試験場彙報, 95, 53-64.
- 106) 田口啓作, 村山大記, 1977. 馬鈴薯, グリーンダイセン普及会, 札幌, 129-130.
- 107) 日本土壌協会, 2012. 野菜の栽培特性に合わせ

- た土づくりと施肥管理Ⅱ， http://www.japan-soil.net/BOOKLET/TK24/TK24_A4.pdf， Accessed November 26， 2020.
- 108) JA千葉みらい農業協同組合，購買品のご紹介， http://www.ja-chibamirai.or.jp/purchased_goods/#goods02， Accessed August 27， 2020.
- 109) JA新居浜市，購買品注文， <https://www.ja-niihamashi.or.jp/shopping/category/item/%E8%82%A5%E6%96%99/>， Accessed August 28， 2020.
- 110) 農林水産省，2014-2018. 農業物価統計調査， <https://www.maff.go.jp/j/tokei/kouhyou/noubukka/>， Accessed September 3， 2020.
- 111) 東北農政局，2013-2014. 第61次山形農林水産統計年報， https://www.maff.go.jp/tohoku/stinfo/oukei/nenpo/61_yamagata.html， Accessed January 14， 2020.
- 112) 金田吉弘，児玉徹，三浦昌司，長野間宏，佐々木昭太郎，1986. 八郎潟干拓地における水稻の栄養診断と追肥の要否判定，東北農業研究，39，55-56.
- 113) 村上英樹，板倉孝司，小田俊光，中津智裕，1994. 水稻の最高分けつ期前後における生育と籾数，日本作物学会中国支部研究集録，35，19-20.
- 114) 竹峰秀祐，力丸厚，高橋一義，樋口泰浩，2007. 写真測量とリモートセンシング，46(4)，61-65.

- 115) 浪川茉莉, 西田瑞彦, 高橋智紀, 金田吉弘, 2016. 日本土壤肥料学雑誌, 87(6), 450-454.
- 116) 農研機構, 1996, 画像解析によるダイズ群落の植被率の計測と生育指標の面的評価法, <http://www.naro.affrc.go.jp/project/results/laboratory/tarc/1995/tohoku95-165.html>, November 20, 2020.
- 117) 新潟農総研, 2009, 重粘土地帯におけるダイズ「エンレイ」の多収事例に基づく収量構成要素と生育指標, http://www.naro.affrc.go.jp/org/narc/seika/kanto21/12/21_12_04.html, November 24, 2020.
- 118) 横堀潤, 2018. ドローンを活用した可変施肥技術と今後の展望, 十勝農業機械化懇話会報, 29-36.
- 119) 住田弘一, 加藤直人, 西田瑞彦, 2005. 田畑輪換の繰り返しや長期畑転換に伴う転作大豆の生産力低下と土壤肥沃度の変化, 東北農業研究センター研究報告, 103, 39-52.
- 120) 農文協編, 2001. 転作全書1 ムギ, 農村漁村文化協会, 東京.
- 121) 森崎耕平, 尾賀俊哉, 浅野智也, 伊藤晃, 2020. コムギ莖立期における UAV リモートセンシングに基づく追肥量の診断, 日本作物学会第249回講演会要旨集, 71.
- 122) 農研機構, 2001, デジタル画像を利用した栄養

成長期のコムギにおける植被率の簡易推定法，<https://www.naro.affrc.go.jp/project/results/laboratory/karc/2001/konarc01-59.html>，Accessed November 23, 2020.

- 123) 島崎由美，渡邊好昭，2010. コムギの子実タンパク質含有率—栽培による制御の可能性—，日本作物学会紀事，79(4)，407-413.
- 124) 谷口義則，藤田雅也，佐々木昭博，氏原和人，大西昌子，1999. 九州地域におけるコムギの粗タンパク質含有率に及ぼす穂孕み期追肥の効果，日本作物学会紀事，68(1)，48-53.
- 125) 渡邊洋一，渡部隆，二瓶直登，丹治克男，遠藤あかり，2005. 小麦「ゆきちから」の追肥による高品質安定栽培技術，東北農業研究，58，53-54.
- 126) 水田圭祐，荒木英樹，中村和弘，松中仁，丹野研一，高橋肇，2017. パン用コムギ品種「ミナミノカオリ」における穂肥重点施肥が収量や子実タンパク質含有率におよぼす影響，日本作物学会紀事，86(4)，319-328.