

令和2年度スマート農業における水稻収量予測 の高度化のための実証調査委託事業

業務実施報告書

2021 年 3 月

一般財団法人 リモート・センシング技術センター

目 次

1. 業務の目的	1
2. 業務の実施作業	1
2. 1 作業計画	1
2. 2 水稻収量予測モデルの有識者検討会の設置・運営	2
2. 3 センシングデータ、気象データ、ほ場の属性情報と収量予測モデルの組み合わせに よるほ場単位又はほ場の区画単位の 10a 当たり収量の予測手法の調査・検討	4
2. 3. 1 年間計画の作成	4
2. 3. 2 収量予測モデルに関する検討	4
2. 3. 2. 1 生育予測モデル	4
2. 3. 2. 2 収量予測モデル	5
2. 3. 2. 3 収量予測モデルに関する検討のまとめ	5
2. 3. 3 収量予測に利用するセンシングデータの検討	5
2. 3. 4 収量予測モデルの検討	6
2. 3. 4. 1 機械学習等を用いた収量予測モデル	6
2. 3. 4. 2 生育モデルを用いた収量予測モデル	10
2. 4 実証実験	11
2. 4. 1 機械学習等を用いた収量予測	13
2. 4. 1. 1 機械学習等を用いた収量予測の実証実験	13
2. 4. 1. 2 機械学習等を用いた収量予測結果の検証	39
2. 4. 1. 3 機械学習等を用いた収量予測結果を踏まえた現場実装の可能性の検討	47
2. 4. 2 生育モデルを用いた収量予測	48
2. 4. 2. 1 生育モデルを用いた収量予測の実証実験	49
2. 4. 2. 2 生育モデルを用いた収量予測結果の検証	56
2. 4. 2. 3 生育モデルを用いた収量予測結果を踏まえた現場実装の可能性の検討	63
2. 5 打ち合わせ会議等の開催	64

1. 業務の目的

スマート農業においては、センシングデータ等を活用、解析した生育診断により、コスト低減や収量・品質の向上を図る技術が開発され、農業経営の高度化が期待されている。

これらのセンシングデータに加えて、気象情報、ほ場の属性情報（土壌、品種、栽培履歴等）、研究機関や民間事業者が有する様々な収量予測モデルを組み合わせ、ほ場単位又はほ場の区画単位の精緻な収量予測モデルを開発し、現場実装することにより、収量データに基づく戦略的・安定的な農業経営の実現に寄与するものと考えられる。

また、収量予測データを筆ポリゴンに紐付け、それらをサンプルデータとして集推計することにより、より広域（集落、市町村単位）な収量を予測することが可能となり、現在、多大な労力を要している水稻作況調査の効率化が期待されるほか、収量予測データと各種属性データ等の重ね合わせにより、高度なデータ分析が可能となるなど、筆ポリゴンを基盤としたデータの付加価値向上によるスマート農業の推進にも貢献することが見込まれる。

本実証調査は、以上の仕組みの構築に向けて、関係者の参画する検討会を開催し、ほ場単位の収量の高精度予測手法の検討、収量予測モデルのプロトタイプモデルの開発・実証実験を行い、その結果を分析して、現場実装に向けた提言を取りまとめることを目的とする。

2. 業務の実施作業

一般財団法人リモート・センシング技術センター（以下、当財団という。）は以下の2. 1～2. 4に示す作業を実施した。

2. 1 作業計画

作業の実施に当たり、実施スケジュールと実施体制図を含む作業計画書を提出し、統計部生産流通消費統計課（以下「担当部署」という。）の承認を得た。実施スケジュールを図 2. 1-1 に、実施体制図を図 2. 1-2 に示す。実施体制図には、本業務の実施を統括する業務責任者及び業務担当者を明記した。

業務内容	2020年						2021年		
	7月	8月	9月	10月	11月	12月	1月	2月	3月
(1) 作業計画書	■								
(2) 有識者検討会の設置・運営	■								
(3) 予測手法の調査・検討									
ア 年間計画の作成	■								
イ 収量予測モデルに関する検討	■								
ウ 収量予測に利用するセンシングデータの検討	■								
エ 収量予測モデルの検討	■								
(4) 実証実験									
ア 受注者による実証実験		■	■	■	■				
イ 収量予測結果の検証					■	■			
ウ 現場実装の可能性の検討						■	■		
(5) 打ち合わせ会議	▲	▲	▲	▲	▲	▲	▲	▲	▲
(6) 業務実施報告							■	■	■

図 2. 1-1 実施スケジュール




図 2.1-2 実施体制図

2.2 水稻収量予測モデルの有識者検討会の設置・運営

ほ場単位又はほ場の区画単位の収量予測モデルの検討に当たり、専門的見地から検討・評価を行うため、有識者検討会（以下「検討会」という。）を設置した。

検討会の検討委員については、農林水産省（以下「貴省」という。）担当部署と相談の上、農業分野における人工衛星、ドローンその他ロボット技術によるセンシング技術に関する学識経験者、水稻の収量予測に関する学識経験者等から3名を、貴省担当部署と相談の上、決定した。検討委員の一覧を表2.2-1に示す。

検討会は、貴省会議室及びオンラインにおいて、計3回開催した。各検討会の内容と開催日の一覧を表2.2-2に示す。

表 2.2-1 検討委員一覧

役職	氏名	所属	役職	専門分野
委員長	長谷川 利拡	(国研) 農研機構 東北農業研究センター	グループ長	水稻の作柄予測、世界の作物生産と収量予測 など
委員	石塚 直樹	(国研) 農研機構 農業環境変動研究センター	上席研究員	衛星情報を用いた農業情報抽出手法の開発、水稻の作柄予測 など
委員	櫻井 玄	(国研) 農研機構 農業環境変動研究センター	研究員	全球作物収量予測モデルの開発、観測データ同化 など

表 2. 2-2 検討会一覧

回	開催日	場所	内容
1	2020 年 10 月 6 日（火）	貴省統計部 第 1 会議室・ オンライン	(1) 運営方針・年間計画の決定 (2) センシングデータの選定・活用方法、 収量予測モデルの選定及び必要なパラメータの選定・取得方法など具体的な事業の実施方針の検討
2	2021 年 1 月 14 日（木）	オンライン	(1) ほ場単位やほ場の区画単位の収量予測の検証結果の検討
3	2021 年 2 月 17 日（水）	オンライン	(1) 本事業における成果及び課題の整理、 現場実装に向けた対応方策等の検討 (2) スマート農業における活用方策、現場実装の有効性、将来的な利活用に向けた検討

2.3 センシングデータ、気象データ、ほ場の属性情報と収量予測モデルの組み合わせによるほ場単位又はほ場の区画単位の 10a 当たり収量の予測手法の調査・検討

2.3.1 年間計画の作成

センシングデータ、気象データ、ほ場の属性情報と収量予測モデルの組み合わせによるほ場単位又はほ場の区画単位の 10a 当たり収量の予測手法の調査・検討に係る年間計画を図 2.1-1 の通り作成した(「(3) 予測手法の調査・検討」に対応)。

2.3.2 収量予測モデルに関する検討

センシングデータを用いた生育予測・収量予測の研究について、論文検索システムである「CiNii」と「Google Scholar」を用いて、海外を含めて論文を収集した。国内の論文検索のためのキーワードは、“稲”もしくは“米”もしくは“水田”と、“リモートセンシング”もしくは“衛星”とし、生育予測モデルについては“モデル”も追加して検索した。海外の論文検索のためのキーワードは、“remote sensing”もしくは“satellite”と“rice”と“yield”とし、生育予測モデルについては“model”も追加して検索した。検索された論文の関連論文も調査対象とした。水田面積把握等生育予測・収量予測でない論文を除外したうえで、収集した論文を生育予測モデルの論文、収量予測モデルの論文に整理した。その結果、生育予測モデルについては 11 編、収量予測モデルについては 14 編収集した。

2.3.2.1 生育予測モデル

生育予測モデルを用いた研究については、以下のものが挙げられる。

1) SIMRIW-RS

SIMRIW-RS(Simulation Model for Rice-Weather relations with Remote Sensing)を用いた研究として、本間他(2012)、Homma, K. et al.(2017)、本間他(2018)が挙げられる。日本の水稻に対する生育モデルはHorie(1987)が開発したSIMRIW(Simulation Model for Rice Weather relations)があり、このSIMRIWに肥料や土壌肥沃度、水ストレスの効果を付け加えたSIMRIW-Rainfed(Homma and Horie 2009)をベースに、リモートセンシング用に開発したものがSIMRIW-RSである。SIMRIW-RSは品種およびほ場(土壌特性)パラメータをあらかじめ設定し、気象データ(最高気温、平均気温、日降水量、日積算日射量)をもとに、日単位で稲の葉面積と乾物重を計算し、リモートセンシングデータを用いてパラメータを調整し、最終的に収量を推定するモデルである。

2) 光合成型モデル

光合成型モデルを用いた研究として、金子(2006)、金子他(2008)が挙げられる。光合成型モデルは、人工衛星のセンサであるNOAA/AVHRRによるデータより得られるNDVIを用いて、光合成、低温、高温障害を考慮入れた穀物生産指標をモデル化したものである。

3) DSSAT モデル

DSSAT(Decision Support Systems for Agrotechnology Transfer)モデルを用いた研究として、Son, N. et al.(2016)が挙げられる。DSSATモデルでは、人工衛星のセンサであるMODISより得られたLAIを用いて、毎日のバイオマスからシミュレーションを行っている。

2.3.2.2 収量予測モデル

収量予測モデルを用いた研究については、以下のものが挙げられる。

1) NDVI による線形回帰

植生指数の 1 つである正規化植生指数(NDVI: Normalized Difference Vegetation Index)による線形回帰を用いた収量予測の研究として、田中他(2016)、河野他(2019)他が挙げられる。NDVI による線形回帰では、人工衛星である Sentinel-2 やドローンを用いて取得した NDVI と収量との線形回帰により収量予測を行っている。

2) NDVI と日射量による線形回帰

NDVI と日射量による線形回帰を用いた収量予測の研究として、脇山他(2003)、濱他(2018)が挙げられる。NDVI と日射量による線形回帰では、人工衛星のセンサである Landsat TM、Landsat ETM や Aqua/MODIS を用いて、出穂期前後の NDVI と日射量を乗算し、それと収量との線形回帰により収量予測を行っている。

3) マルチバンドによる線形回帰等

マルチバンドによる線形回帰を用いた収量予測の研究として、竹澤他(2007)、吉田他(2012)が挙げられる。竹澤他(2007)では人工衛星 Terra に搭載された ASTER 15 バンド(可視・近赤外・短波長赤外・熱赤外)、吉田他(2012)では航空機に搭載されたハイパースペクトルセンサ HyMap より得られた 86 バンド(450~2490nm)を用いて、収量との線形回帰等により収量予測を行っている。

2.3.2.3 収量予測モデルに関する検討のまとめ

生育予測モデルでは、センシングデータをモデルの入力データもしくはパラメータの調整用データとして用いられている。収量予測モデルでは、センシングデータと収量との回帰式から収量予測を行っている。NDVI と日射量による線形回帰では出穂期前後のデータを用いることで高い精度で収量予測ができています。また、マルチバンドによる線形回帰においても高い精度で収量予測ができています。これらを踏まえ、収量予測モデルでは出穂期前後の植生指数や日射量、また各バンドを用いることで精度向上につながると考えられる。

2.3.3 収量予測に利用するセンシングデータの検討

収量予測に利用するセンシングデータには人工衛星、ドローン等が挙げられる。このうち、ドローンは人工衛星と比較して空間分解能の非常に高いデータが得られるが、収量予測モデルを作成するためには複数地点のデータが必要となり、データ取得に多くの費用、労力がかかること、また過去のデータを取得できないことから、今回の収量予測に利用するセンシングデータの対象から除外した。

人工衛星については、空間分解能が 2m 以下の WorldView-2, 3, 4 等の高分解能衛星、空間分解能が約 3.7m で観測されている PlanetScope、空間分解能が 10~30m の Landsat や Sentinel-2、空間分解能が約 250m~1km の GCOM-C/SGLI、空間分解能が約 250m~1km の Terra/MODIS や Aqua/MODIS 等が挙げられる。

このうち、高分解能衛星や PlanetScope は有償であり、収量予測モデルを作成するためには多くのデータが必要となるため、今回の収量予測に利用するセンシングデータの対象から除外した。

次に、Landsat や Sentinel-2 は回帰日数が 10～16 日であり、出穂期前後の雲の無い画像が必ずしも入手できるとは限らない。過去のデータの確認より、出穂期前後に雲の無い画像を取得できる年は 2 年に 1 度程度しかないため、今回の収量予測に利用するセンシングデータの対象から除外した。

GCOM-C/SGLI は 2018 年以降のデータしかないことから、今回の収量予測に利用するセンシングデータの対象から除外した。

Terra/MODIS や Aqua/MODIS は空間分解能が約 250m～1km と低いものの、2,300km 以上の広い観測幅でデータを取得するため、日本全域をほぼ 1 日で観測できる。アメリカ地質調査所(USGS: United States Geological Survey) のサイトから無料でダウンロードでき、雲の影響を極力除外した 8 日間もしくは 16 日間合成プロダクトが公開されており、Terra/MODIS は 2000 年から現在まで、Aqua/MODIS は 2003 年から現在まで運用されており、収量予測モデルを作成するための多くのデータが入手可能であることから今回 Terra/MODIS を用いることとした。そして、Terra/MODIS のデータを説明変数、収量を目的変数とした機械学習もしくは重回帰式により、収量予測モデルを作成した。生育モデルについては、Terra/MODIS と Aqua/MODIS を用いることとした。

その他のデータとして、気象データとしてアメダス観測データを用いることとした。

2.3.4 収量予測モデルの検討

収量予測モデルとして、ランダムフォレストによる機械学習等を用いた収量予測モデルと、SIMRIW-RS による生育モデルを用いた収量予測を行うこととした。

ランダムフォレストは衛星データ等と収量との関連性が低い場合でも、それらを多数寄せ集めることによって推定モデルを構築する手法であり、特徴量が非常に多いデータセットでも高速に解析ができ、比較的高い予測精度が期待できる。また、パラメータの重要度が算出できるため、収量予測に重要なパラメータを把握できる点で優れていると考えられる。

SIMRIW-RS は、生育モデルである SIMRIW をリモートセンシングデータ用に改良したもので成長過程をシミュレーションするモデルであり、稲の成長という時間軸を考慮する場合に効果的であると言われている。

2.3.4.1 機械学習等を用いた収量予測モデル

1) パラメータの取得

機械学習等を用いた収量予測のパラメータとして、使用する衛星データと気象データを検討の上、選定を行った。選定した衛星データと気象データの一覧を表 2.3.4.1-1 に示す。

衛星データについては、米国航空宇宙局(NASA: National Aeronautics and Space Administration)より委託を受けた USGS の LP DAAC(The Land Processes Distributed Active Archive Center) (<https://lpdaac.usgs.gov/>) から無償で提供されている Terra と Aqua に搭載されている以下の MODIS データをダウンロードして用いた。

- ・ 青、緑、赤、近赤外 4 バンド(バンド 1～4)の地表面反射率(8 日間合成)
(バンド 1, 2: 250m 分解能、バンド 3, 4: 500m 分解能)
- ・ 地表面温度(LST: Land Surface Temperature)(8 日間合成)(1km 分解能)
- ・ 葉面積指数(LAI: Leaf Area Index)(8 日間合成)(500m 分解能)
- ・ 光合成有効放射吸収率(FPAR: Fraction of Photosynthetically Active

Radiation)

(8 日間合成) (500m 分解能)

- ・ 拡張植生指数 (EVI: Extended Vegetation Index) (16 日間合成) (250m 分解能)

また、日射量は Terra/MODIS のデータを航空宇宙研究開発機構 (JAXA: Japan Aerospace Exploration Agency) から提供されている JASMES (JAXA Satellite Monitoring for Environmental Studies: 気候形成物理量データセット) (https://www.eorc.jaxa.jp/JASMES/index_map_j.html) より無償でダウンロードしてパラメータとして用いた。JASMES は米国の Terra/MODIS 等から算定した気候データセットである。そのうえで、拡張植生指数 EVI と日射量の積のデータを作成し、パラメータとして用いた。

- ・ 日射量 (SWR: Short Wave Radiation) (1km 分解能)

気象データとして以下のアメダス観測データを、気象庁の Web ページ (<https://www.data.jma.go.jp/obd/stats/etrn/index.php>) より無償でダウンロードしてパラメータとして用いた。

- ・ 降水量
- ・ 平均気温
- ・ 日照時間
- ・ 風速

アメダスが観測している気象項目は観測地点によって異なり、降水量のみと、降水量・気温・日照時間・風向風速の 4 項目が観測されている地点に分けられる。本業務では降水量・気温・日照時間・風向風速の 4 項目が観測されているアメダスデータを使用した。本業務では気象庁の Web ページで提供されている日別データを使用した。

収量データ、田植日と出穂日については貴省担当部署より入手した坪刈りデータである「筆成績一覧表」を用いた。収量データについて、緯度・経度が茨城県外のものを異常データとして除外した。田植期、出穂期、刈取り期の日付が不明なものや田植期と出穂期の日付が逆になっているものなどの異常データを除外した。

収量データの位置情報は緯度経度の分単位であり、ほ場単位の粒度での実証と検証が困難なため、解析単位を図 2.3.4.1-1 に示す通り 20km メッシュから 10km、5km、1km メッシュと小さくしていくこととした。そして、解析単位ごとに収量、衛星データ、気象データ、田植日、出穂日を平均して解析に用いた。その上で、解析単位の違いによる傾向から、解析単位を小さくした場合の留意事項を整理し、解析単位をほ場単位とする実装に向けた検討を行った。



図 2.3.4.1-1 解析単位イメージ

解析単位は3次メッシュ(約1kmメッシュ)を総務省統計局が整備したe-Stat(政府統計の総合窓口)より無償でダウンロードした。GISソフトを用いて3次メッシュを結合させて、約5kmメッシュ、約10kmメッシュ(2次メッシュ)、約20kmメッシュを作成した。

また、メッシュの緯度、経度として各解析単位の重心の緯度経度をGISソフトにより取得してパラメータとして用いた。

水田位置は、貴省が整備している農地の区画情報(筆ポリゴン)(<https://www.maff.go.jp/j/tokei/polygon/index.html>)の最新データのうち、耕地の種類が”田”を利用した。農地の区画情報の”田”の例を図2.3.4.1-2に示す。



図 2.3.4.1-2 農地の区画情報(筆ポリゴン)の”田”の例

表 2.3.4.1-1 衛星データと気象データ等一覧

区分	データ種類	分解能	入手元	提供機関
衛星データ	赤、近赤外 2 バンド (バンド 1・2) の地表面反射率	250m	LP DAAC	NASA/USGS
	青、緑 2 バンド (バンド 3・4) の地表面反射率	500m		
	地表面温度 (LST)	1km		
	葉面積指数 (LAI)	500m		
	光合成有効放射吸収率 (FPAR)	500m		
	植生指数 (EVI)	250m		
	日射量 (SWR)	1km	JASMES	JAXA
気象データ	降水量		AMeDAS	気象庁
	平均気温			
	日照時間			
	風速			
収量データ等	収量データ		筆成績 一覧表	貴省
	田植日			
	出穂日			
その他	3 次メッシュ (約 1km メッシュ)		e-Stat	総務省 統計局
	水田位置		農地の区画 情報 (筆ポ リゴン)	貴省

2) 収量予測モデルの作成

機械学習等を用いた収量予測モデルとして、ランダムフォレストを用いて表 2.3.4.1-2 に示すパラメータを組み合わせた複数の収量予測モデルを作成した。衛星データを使用する収量予測モデルについては、EVI を前後 3 期間でスムージングしたもの (EVI 前後 3 期間) と前後 5 期間でスムージングしたもの (EVI 前後 5 期間) とをそれぞれ作成した。そして、解析単位ごとに表 2.3.4.1-2 に示す 17 モデルを作成した。さらに、解析単位ごとに最も精度が高いモデルについて、平年収量を加えたモデルを作成した。

その上で、各解析単位で最も精度の高いモデルを採用した。精度の評価指標として、RMSE (Root Mean Squared Error: 平均平方根二乗誤差) を用いた。RMSE は、外れ値の誤差ができるだけ小さいモデルを選択したい場合に有効である。

また、最も精度の高い解析単位については、重回帰モデルの作成を行った。

表 2.3.4.1-2 作成した収量予測モデルのパラメーター一覧

収量予測モデルのパラメータ	
1	気象データのみ
2	衛星データのみ (EVI 前後 3 期間)
3	衛星データのみ (EVI 前後 5 期間)
4	衛星データ+緯度経度 (EVI 前後 3 期間)
5	衛星データ+緯度経度 (EVI 前後 5 期間)
6	衛星データ+田植日出穂日 (EVI 前後 3 期間)
7	衛星データ+田植日出穂日 (EVI 前後 5 期間)
8	衛星データ+緯度経度+田植日出穂日 (EVI 前後 3 期間)
9	衛星データ+緯度経度+田植日出穂日 (EVI 前後 5 期間)
10	衛星データ+気象データ (EVI 前後 3 期間)
11	衛星データ+気象データ (EVI 前後 5 期間)
12	衛星データ+気象データ+緯度経度 (EVI 前後 3 期間)
13	衛星データ+気象データ+緯度経度 (EVI 前後 5 期間)
14	衛星データ+気象データ+田植日出穂日 (EVI 前後 3 期間)
15	衛星データ+気象データ+田植日出穂日 (EVI 前後 5 期間)
16	衛星データ+気象データ+緯度経度+田植日出穂日 (EVI 前後 3 期間)
17	衛星データ+気象データ+緯度経度+田植日出穂日 (EVI 前後 5 期間)

2.3.4.2 生育モデルを用いた収量予測モデル

生育モデルを用いた収量予測においては、生育モデルとして SIMRIW-RS を用いた。

SIMRIW-RS のパラメータの調整用のデータとして、以下の Terra/MODIS と Aqua/MODIS のデータを USGS の LP DAAC より無償でダウンロードして用いた。正規化植生指数 (NDVI: Normalized Difference Vegetation Index) は 250m メッシュの 16 日間合成のものを用いた。日付は 16 日間の開始日を使用した。Terra/MODIS と Aqua/MODIS を合わせ、8 日間隔のデータとして使用した。LAI は 500m メッシュの 8 日間合成のものを使用した。

- ・葉面積指数 (LAI) (8 日間合成) (500m 分解能)
- ・正規化植生指数 (NDVI) (16 日間合成) (250m 分解能)

収量データは貴省担当部署より入手した刈りデータである「茨城県筆成績一覧表」を用いた。収量データの位置は「茨城県筆成績一覧表」の緯度、経度を利用した。緯度・経度が茨城県外のものを異常データとして除外した。田植期、出穂期、刈取り期の日付が不明なものや田植期と出穂期の日付が逆になっているものなどの異常データを除外した。

2.4 実証実験

収量予測に関する実証実験を行い、問題点や課題を抽出し、課題解決のための方策を検討した。実施した収量予測は、機械学習等を用いた収量予測と、生育モデルを用いた収量予測である。

実証実験を実施するにあたり、対象県と対象品種の検討を行った。東北と北関東各県の筆成績一覧表を貴省より受領し、各県の坪刈りの地点数、100 ㎡あたりの坪刈りの地点数を算出した。また、2009 年から 2018 年までの県別快晴日数のデータを埼玉県の Web ページ(https://www.pref.saitama.lg.jp/a0206/kodomo/documents/d14_01_g11_kaisei10y2009~2018.xlsx)より入手した。Terra/MODIS のような光学衛星リモートセンシングデータを用いる場合には、雲によるデータの欠損が少ない地域を対象とすることが望ましい。2009 年から 2018 年までの東北、北関東の各県の快晴日数を表 2.4-1 に示す。表 2.4-1 より快晴日数は北関東で多く、東北では少ない傾向(北関東各県の 1/3 から 1/4)にあり、その中でも茨城県において快晴日数が最も多い。そこで、対象を北関東 3 県(茨城県、栃木県、群馬県)の中から選定することとした。北関東 3 県の坪刈りの地点数、100 ㎡あたりの坪刈りの地点数を表 2.4-2 に示す。表 2.4-2 より、北関東 3 県の中で茨城県が坪刈りの地点数、100 ㎡あたりの坪刈りの地点数ともに最も多い。

東北・北関東の各県のうち、快晴日数が最も多いこと、北関東の各県のうち、坪刈りの地点数、100 ㎡あたりの坪刈りの地点数が最も多いことを踏まえ、対象県として茨城県を選定した。

表 2.4-1 県別快晴日数

年	平成21 2009	平成22 2010	平成23 2011	平成24 2012	平成25 2013	平成26 2014	平成27 2015	平成28 2016	平成29 2017	平成30 2018	10年間の 合計
青森県	7	8	8	19	9	18	11	13	14	8	115
岩手県	8	9	13	10	5	17	16	11	9	8	106
宮城県	9	7	14	5	15	22	13	12	13	20	130
秋田県	9	9	10	13	10	16	13	9	6	9	104
山形県	8	10	17	4	11	15	9	11	10	8	103
福島県	14	9	13	7	14	19	11	11	14	14	126
茨城県	40	30	43	40	53	46	42	31	45	44	414
栃木県	29	21	42	25	46	50	42	34	45	28	362
群馬県	34	25	39	36	52	40	37	46	42	34	385

表 2.4-2 北関東 3 県の坪刈りの地点数、100 km²あたりの坪刈りの地点数

茨城県

年	地点数	100km ² あたり
2010	301	4.94
2011	303	4.97
2012	295	4.84
2013	295	4.84
2014	295	4.84
2015	295	4.84
2016	294	4.82
2017	294	4.82
2018	294	4.82
2019	293	4.81
平均	295.9	4.85

栃木県

年	地点数	100km ² あたり
2010	292	4.56
2011	292	4.56
2012	288	4.49
2013	288	4.49
2014	288	4.49
2015	288	4.49
2016	288	4.49
2017	288	4.49
2018	288	4.49
2019	288	4.49
平均	288.8	4.51

群馬県

年	地点数	100km ² あたり
2010	197	3.10
2011	197	3.10
2012	188	2.96
2013	188	2.96
2014	188	2.96
2015	188	2.96
2016	188	2.96
2017	188	2.96
2018	188	2.96
2019	188	2.96
平均	189.8	2.98

次に、茨城県筆成績一覧表より茨城県の品種別坪刈り地点数を算出した。その結果を表 2.4-3 に示す。表 2.4-3 より、茨城県において品種別ではコシヒカリが坪刈り地点が一番多く、全体の 8 割以上を占めることがわかった。

そこで、対象品種としてコシヒカリを選定した。

表 2.4-3 茨城県の品種別坪刈り地点数

品種	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	総計
コシヒカリ	244	257	260	258	245	244	243	243	252	253	246	251	245	240	229	230	230	4170
あきたこまち	29	28	32	28	26	34	33	29	30	29	29	26	27	35	42	42	36	535
ゆめひたち	9	3	2	4	8	9	7	7	5	4	3	1	4	2	1	5	4	78
ミルキークイーン	1			6	7	2	4	4	4	3	8	4	4	5	4	5	4	65
ひとめぼれ	10	5	5	4	3	6	7	5	6	2		1	2			2	4	62
チヨニシキ	10	11	4	3	4	3	2	8	2		2	3	3	3	2		1	61
キヌヒカリ	5	3	2	5	6	3	3	1	1	2	1	2	3	3	3	2	1	46
ふくまる											3	3	2	2	3	3	5	21
マンゲツモチ			3	1	1		1	2					3	2	2		1	16
つくばSD2号															3		1	4
とよめき															1	2	1	4
水稻うるち米その他														1	1	1	1	4
あさひの夢									1			1				1		3
ふさおとめ											1	1	1					3
あきだわら												1			1			2
ヒカリ新世紀											1	1						2
ほしじるし																	2	2
一番星														1		1		2
きらら397								1										1
こしいぶき									1									1
つくばSD1号																	1	1
ハナエチゼン									1									1
はるみ																	1	1
ヒメノモチ										1								1
ふさのもち														1				1
みつひかり															1			1
ユメヒカリ										1								1
湘南6号											1							1
赤糯															1			1
萌えみのり								1										1
その他	1	2	1				1											5
総計	309	309	309	309	300	301	301	301	303	295	295	295	295	294	294	294	293	5097

2.4.1 機械学習等を用いた収量予測

機械学習等を用いた収量予測について、実証実験、収量予測結果の検証を行い、現場実装の可能性の検討を行った。

2.4.1.1 機械学習等を用いた収量予測の実証実験

機械学習等を用いた収量予測の実証実験として、データセットを作成し、ランダムフォレストを用いた収量予測モデルの精度評価とそれを用いたほ場単位の水稲の収穫前の10a当たり収量の予測、並びに重回帰分析による精度評価を行った。実証実験のフローを図2.4.1.1-1に示す。




図 2.4.1.1-1 実証実験のフロー

1) データセットの作成

収量データ、衛星データ、気象データを入手と編集を行い、解析単位で期間毎に集計を行い、田植日、出穂日等を追加してデータセットを作成した。データセットの概要を図2.4.1.1-2に示す。




図 2.4.1.1-2 データセットの概要

(1) 収量データの入手と編集

収量データは貴省より受領した「茨城県筆成績一覧表」を用いた。収量は「茨城県筆成績一覧表」にある 10a 再選別玄米重を使用した。

まず、「茨城県筆成績一覧表」から品種がコシヒカリのデータを抽出した。その上で、緯度・経度が茨城県外のものを異常データとして除外した。次に、田植期、出穂期、刈取り期の日付が不明なものや田植期と出穂期の日付が逆になっているものなどの異常データを除外した。

異常データを除外した後の収量データのヒストグラムを図 2.4.1.1-3 に示す。収量は平均が 518.7 kg/10a、標準偏差が 104.8 kg/10a となり、外れ値も見られた。そこで、 $\text{平均値} \pm 3 \times \text{標準偏差}$ ($\mu \pm 3\sigma$) の外側 (204.3 以下、833.1 以上) を外れ値として除外した。

そして、解析単位ごとの収量、田植日、出穂日、刈取り日の平均値を算出した。




図 2.4.1.1-3 収量データのヒストグラム

(2) 衛星データの入手と編集

衛星データは LP DAAC および JASMES より入手した。各画像の確認を行い、明らかな異常が見られた青、緑、赤、近赤外 4 バンドの地表面反射率、葉面積指数(LAI) と光合成有効放射吸収率(FPAR)については閾値を設け、異常値を無効値とした。

水田以外のピクセルを除外するために、衛星データと農地の区画情報(筆ポリゴン)の”田”を重ね合わせ、水田が含まれない衛星データのピクセルを無効値として除外した。

無効値を除外した衛星データについて、解析単位で平均をとり、解析単位で集計した。なお、解析単位に無効値が含まれる場合はその値を除いた平均値とした。解析単位においてすべてが無効値の場合にはその前後の期間から補完した。

(3) 気象データの入手と編集

気象データについては、衛星データの 16 日間データにあわせ、降水量については 16 日間の積算値を、気温、日照時間、風速については 16 日間の平均値をアメダス地点ごとに算出した。次にアメダス地点を母点としてボロノイ分割を行った。ボロノイ分割とは、複数の母点(今回の場合アメダス地点)に対して、どの母点に最も近いかにによってポリゴンを分割する手法である。茨城県をアメダス地点によってボロノイ分割した図を図 2.4.1.1-4 に示す。そして、農地の区画情報(筆ポリゴン)の”田”を利用し、解析単位ごとに、各アメダス地点からボロノイ分割したポリゴンのうち水田メッシュの面積割合を求め、アメダスデータと面積割合をかけてアメダスデータを按分することによって、解析単位ごとの気象データを作成した。

気象データには欠測が存在したため補完した。茨城県内のすべてのアメダス地点の測定項目の決定係数を算出し、欠測が存在するアメダスの測定値と同等の傾向を示すアメダス地点を求めた。あるアメダス地点で欠測があった場合、最も決定係数が高いアメダス地点の測定値を取得した。仮に決定係数が最も高いアメダス地点も欠測していた場合、次に高い決定係数を持つアメダス地点のデータを取得した。ただし、取得したデータをそのまま代入すると、他地点の気象の傾向が反映されてしまうことから、観測項目ごとに欠測のあったアメダス地点と参照したアメダス地点の累積関数を求め、この累積関数

を考慮したデータを補完した。なお、累積関数の確率分布は、気温は正規分布、降水量・日照時間・風速はガンマ分布とした。この補完により、気象データの欠測値を全て埋めることができた。




図 2.4.1.1-4 アメダス地点によるボロノイ分割

(4) 期間ごとの集計

衛星データと気象データについては収量と関係があると考えられる、①出穂日の約 2～1 か月前、②約 1 か月前～出穂日、③出穂日以降～約 1 か月後の期間を対象とした 3 変数を作成した。

解析単位ごとに出穂日の平均値を算出し、出穂日を含む期間を” 0” として、その 1 つ前の時期のデータを” -1”、2 つ前の時期のデータを” -2”、1 つ後の時期のデータを” +1”、2 つ後の時期のデータを” +2” とした場合、8 日間データは、①出穂日の約 2～1 か月前のデータは” -7” ～” -4”、②約 1 か月前～出穂日のデータは” -3” ～” 0”、③出穂日以降～約 1 か月後のデータは” +1” ～” +4” を用いて、その期間に含まれるデータの平均値をそれぞれの変数とした。16 日間データは、①出穂日の約 2～1 か月前のデータは” -3” ～” -2”、②約 1 か月前～出穂日のデータは” -1” ～” 0”、③出穂日以降～約 1 か月後のデータは” +1” ～” +2” を用いて、その期間に含まれるデータの平均値をそれぞれの変数とした。模式図を図 2.4.1.1-5 に示す。




図 2.4.1.1-5 期間ごとの集計

(5) 説明変数の追加

収量に関係があると考えられる衛星データ、気象データ以外のデータを追加し、データセットを作成した。

田植日、出穂日は「茨城県筆成績一覧表」のものを利用した。そして、各年の解析単位ごとに田植日、出穂日の1月1日からの平均日数を算出し、データセットに追加した。

メッシュの重心の緯度・経度は、e-Stat よりダウンロードした3次メッシュ(約1kmメッシュ)から作成した5kmメッシュ、10kmメッシュ、20kmメッシュの重心の緯度経度をGISソフトにより取得し、データセットに追加した。緯度・経度は地域的な収量の傾向を反映できると考えられる。

平年収量は貴省から提供された茨城県の作柄表示地帯別平年収量を利用した。そして、解析単位ごとに、作柄表示地帯ポリゴンのうち水田メッシュの面積割合を求め、平年収量と面積割合をかけて平年収量を按分することによって、解析単位ごとの平年収量データセットを作成した。

(6) 9月15日予測データ、全期間実測値データの作成

貴省では毎年、9月15日現在における作柄概況を公表している。本業務ではほ場単位の水稲の収穫期前の10a当たり収量の予測として、9月15日現在の収量予測を行った。そのために、9月15日予測データ、全期間実測値データの2つのセットを作成した。その概要を図2.4.1.1-6に示す。9月15日予測データは、9月14日までのデータを実測値とし、9月15日以降のデータを平年値とした。全期間実測値データはすべての期間において実測値とした。全期間実測値データは収量予測モデルの作成ならびに精度評価のために使用した。各データの期間は、出穂日の約2か月前から出穂日の約1か月後までとした。

9月15日予測データ

実測値

平年値

全期間実測値データ

実測値

図 2.4.1.1-6 9 月 15 日予測データ、全期間実測値データの概要

2) 機械学習等を用いた収量予測の手法

(1) 収量予測モデルの作成手法

収量予測モデルは「2.3.4.1 2) 収量予測モデルの作成」の表 2.3.4.1-2 に示す収量予測モデルを用いた。そして、解析単位で最も精度の高いモデルを採用した。

モデルの精度評価には、交差検証法を用いた。交差検証法は少ないデータでもモデルの頑健性の評価が可能である。本業務の交差検証では、検証年のデータを1年だけ除いて残りのすべての年のデータをトレーニングデータとしてモデルを作成し、除いた1年のデータを検証データとして、予測値と実測値との誤差を求めて、モデルの頑健性を評価する Leave-one-out (L00) 法を用いた。本業務では17年分のデータを用いており、L00の誤差は17回算出される。これらの誤差をそのモデルの交差検証誤差とした。交差検証法の概要を図 2.4.1.1-7 に示す。

精度の評価指標として、予測値と実測値との RMSE を用いた。

最も精度が高いモデルについて、平年収量を加えたモデルを作成し、精度の比較を行った。平年収量を変数に追加することで、その土地固有の収量レベルの誤差を軽減できると考えられる。

各解析単位で最も精度が高いモデルについて、水田面積割合が多いメッシュを対象にランダムフォレストによる予測を行った。そして、実測値との比較を行い、田の割合が多いメッシュのみを対象としたモデルの精度を確認した。




図 2.4.1.1-7 交差検証法の概要

(2) 重回帰分析の作成手法

収量予測モデルについて最も精度の高い解析単位において重回帰分析を行った。最も精度の高い解析単位において、全ての変数を含めた「衛星データ+気象データ+緯度経度+田植日出穂日」の収量予測モデルで、植生指数の EVI は前後 3 期間でスムージングしたものと、前後 5 期間でスムージングしたもので RMSE の小さいほうのモデルについて、ランダムフォレストによる変数の重要度を算出した。そして、重要度の上位の変数のうち、風速といった通常相関があるとは考えにくい変数を除外し、作柄表示地帯をダミー変数として追加した。地域ごとに収量差があると考え、その補正のための固定効果として作柄表示地帯をダミー変数として追加した。

多重共線性を考慮し、分散拡大指数(VIF)が 10 以上の変数を除外した。そして、ステップワイズ法により説明変数の選択を行った。ステップワイズ法は変数減増法を用いた。ステップワイズ法は適合度の良いモデルを作成するために、説明変数の絞り込みに用いられる手法である。最後に、予測式の検証として、交差検証法を用いて検証年を除いた学習年で予測式を作成し、検証年で検証した。

(3) ほ場単位の水稲の収穫期前の 10a 当たり収量の予測手法

ほ場単位の水稲の収穫期前の 10a 当たり収量の予測として、9 月 15 日の予測を行った。表 2.3.4.1-2 に示した各解析単位の収量予測モデルのうち、RMSE を用いて最も精度が高いモデルを解析単位ごとに採用した。そして、全期間実測データを用いて解析単位ごとに予測を行い、その予測値を一番小さい解析単位である 1km メッシュ単位に変換した。そして、1km メッシュの実測値と 1km、5km、10km、20km メッシュの予測値との誤差について RMSE を用いて算出した。そして、RMSE が最も小さい解析単位とその収量予測モデルを 9 月 15 日現在の予測のためのモデルとして用いた。

採用した解析単位とその収量予測モデルについて、全期間実測データを用いて予測年を除いた年のデータをトレーニングデータとして、識別器を作成した。そして、9 月 15 日予測データを入力データとして、作成した識別器を用いてそれぞれの解析単位ごとの

予測を行った。なお、収量データが無いメッシュの田植日、出穂日については、各年の県全体の田植日、出穂日の平均値で補完した。

最後に予測値を筆ポリゴンと結び付け、各年の筆ポリゴンごとの 9 月 15 日現在の予測値を作成した。

3) 機械学習等を用いた収量予測の結果

(1) 収量予測モデルの精度評価の結果

1km メッシュ、5km メッシュ、10km メッシュ、20km メッシュの各解析単位について、複数の収量予測モデルを用いて予測値を算出して実測値との比較を行い、RMSE により精度評価を行った。1km メッシュの各収量予測モデル別 RMSE の結果を表 2.4.1.1-1、5km メッシュの各収量予測モデル別 RMSE の結果を表 2.4.1.1-2、10km メッシュの各収量予測モデル別 RMSE の結果を表 2.4.1.1-3、20km メッシュの各収量予測モデル別 RMSE の結果を表 2.4.1.1-4 に示す。

表 2.4.1.1-1 1km メッシュの各収量予測モデル別 RMSE の結果

収量予測モデル	RMSE
衛星データ(EVI前後3期間)	65.65
衛星データ+緯度経度(EVI前後3期間)	64.72
衛星データ+田植日出穂日(EVI前後3期間)	65.35
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	64.39
衛星データ+気象データ(EVI前後3期間)	65.69
衛星データ+気象データ+緯度経度(EVI前後3期間)	65.37
衛星データ+気象データ+田植日出穂日(EVI前後3期間)	64.44
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後3期間)	64.55
衛星データ(EVI前後5期間)	65.52
衛星データ+緯度経度(EVI前後5期間)	64.76
衛星データ+田植日出穂日(EVI前後5期間)	65.07
衛星データ+緯度経度+田植日出穂日(EVI前後5期間)	64.57
衛星データ+気象データ(EVI前後5期間)	65.86
衛星データ+気象データ+緯度経度(EVI前後5期間)	65.17
衛星データ+気象データ+田植日出穂日(EVI前後5期間)	64.93
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後5期間)	64.72
気象データ	67.04

表 2.4.1.1-2 5km メッシュの各収量予測モデル別 RMSE の結果

収量予測モデル	RMSE
衛星データ(EVI前後3期間)	57.62
衛星データ+緯度経度(EVI前後3期間)	57.66
衛星データ+田植日出穂日(EVI前後3期間)	57.64
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	57.21
衛星データ+気象データ(EVI前後3期間)	57.95
衛星データ+気象データ+緯度経度(EVI前後3期間)	57.52
衛星データ+気象データ+田植日出穂日(EVI前後3期間)	57.98
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後3期間)	57.88
衛星データ(EVI前後5期間)	57.77
衛星データ+緯度経度(EVI前後5期間)	57.48
衛星データ+田植日出穂日(EVI前後5期間)	57.63
衛星データ+緯度経度+田植日出穂日(EVI前後5期間)	57.35
衛星データ+気象データ(EVI前後5期間)	58.19
衛星データ+気象データ+緯度経度(EVI前後5期間)	58.21
衛星データ+気象データ+田植日出穂日(EVI前後5期間)	57.86
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後5期間)	57.96
気象データ	58.58

表 2.4.1.1-3 10km メッシュの各収量予測モデル別 RMSE の結果

収量予測モデル	RMSE
衛星データ(EVI前後3期間)	46.97
衛星データ+緯度経度(EVI前後3期間)	46.60
衛星データ+田植日出穂日(EVI前後3期間)	46.81
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	46.32
衛星データ+気象データ(EVI前後3期間)	46.62
衛星データ+気象データ+緯度経度(EVI前後3期間)	46.84
衛星データ+気象データ+田植日出穂日(EVI前後3期間)	46.28
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後3期間)	46.62
衛星データ(EVI前後5期間)	46.76
衛星データ+緯度経度(EVI前後5期間)	46.53
衛星データ+田植日出穂日(EVI前後5期間)	46.44
衛星データ+緯度経度+田植日出穂日(EVI前後5期間)	46.66
衛星データ+気象データ(EVI前後5期間)	46.48
衛星データ+気象データ+緯度経度(EVI前後5期間)	46.95
衛星データ+気象データ+田植日出穂日(EVI前後5期間)	46.84
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後5期間)	46.68
気象データ	49.33

表 2.4.1.1-4 20km メッシュの各収量予測モデル別 RMSE の結果

収量予測モデル	RMSE
衛星データ(EVI前後3期間)	38.60
衛星データ+緯度経度(EVI前後3期間)	38.47
衛星データ+田植日出穂日(EVI前後3期間)	38.63
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	39.00
衛星データ+気象データ(EVI前後3期間)	38.92
衛星データ+気象データ+緯度経度(EVI前後3期間)	39.09
衛星データ+気象データ+田植日出穂日(EVI前後3期間)	38.65
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後3期間)	39.13
衛星データ(EVI前後5期間)	38.26
衛星データ+緯度経度(EVI前後5期間)	38.51
衛星データ+田植日出穂日(EVI前後5期間)	39.04
衛星データ+緯度経度+田植日出穂日(EVI前後5期間)	38.47
衛星データ+気象データ(EVI前後5期間)	38.82
衛星データ+気象データ+緯度経度(EVI前後5期間)	38.96
衛星データ+気象データ+田植日出穂日(EVI前後5期間)	39.18
衛星データ+気象データ+緯度経度+田植日出穂日(EVI前後5期間)	39.36
気象データ	39.19

表 2.4.1.1-1 より、1km メッシュの収量予測モデルにおいては、気象データのみよりも衛星データ、もしくは衛星データの組み合わせのほうが、精度が高くなった。その中でも、「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデル」の RMSE が最も小さくなり、精度が高いことがわかった。このときの予測値と実測値の散布図を図 2.4.1.1-8 に示す。

表 2.4.1.1-2 より、5km メッシュの収量予測モデルにおいては、気象データのみよりも衛星データ、もしくは衛星データの組み合わせのほうが、精度が高くなった。その中でも、「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデル」の RMSE が最も小さくなり、精度が高いことがわかった。このときの予測値と実測値の散布図を図 2.4.1.1-9 に示す。

表 2.4.1.1-3 より、10km メッシュの収量予測モデルにおいては、気象データのみよりも衛星データ、もしくは衛星データの組み合わせのほうが、精度が高くなった。その中でも、「EVI 前後 3 期間でスムージングした衛星データ+気象データ+田植日出穂日を組み合わせた収量予測モデル」の RMSE が最も小さくなり、精度が高いことがわかった。このときの予測値と実測値の散布図を図 2.4.1.1-10 に示す。

表 2.4.1.1-4 より、20km メッシュの収量予測モデルにおいては、気象データのみよりも衛星データ、もしくは衛星データの組み合わせのほうが一部の収量予測モデルを除いて精度が高くなった。その中でも、「EVI 前後 5 期間でスムージングした衛星データの収量予測モデル」の RMSE が最も小さくなり、精度が高いことがわかった。このときの予測値と実測値の散布図を図 2.4.1.1-11 に示す。また、各解析単位で最も精度が高いモデルの RMSE の年変動を図 2.4.1.1-12 に示す。

表 2.4.1.1-1～表 2.4.1.1-4 より、どの解析単位においても気象データよりも衛星データのほうが精度が高く、一部を除いて気象データと衛星データの組み合わせのほうが、

精度が高いことがわかった。特に解析単位が小さい時にこの傾向が顕著にあらわれた。このことより、特に解析単位が小さい場合には、衛星データの利用した予測の可能性が確認できた。

また、全体的には、メッシュサイズが大きくなるにつれ精度が高くなる傾向が見られた。年別においても図 2.4.1.1-12 より一部の年を除いて、メッシュサイズが大きくなるにつれ精度が高くなる傾向が見られた。

また、図 2.4.1.1-8～図 2.4.1.1-11 の散布図よりすべての解析単位において予測値と実測値との間に一定の関係性が見られたが、実測値が高い場合と低い場合にうまく予測できていない傾向が見られた。




図 2.4.1.1-8 1km メッシュとした場合の EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデルの予測値と実測値の散布図
(データ数が多いため濃淡をつけて図示)




図 2.4.1.1-9 5km メッシュとした場合の EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-10 10km メッシュとした場合の EVI 前後 3 期間でスムージングした衛星データ+気象データ+田植日出穂日を組み合わせた収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-11 20km メッシュとした場合の EVI 前後 5 期間でスムージングした衛星データの収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-12 各解析単位で最も精度が高いモデルの RMSE の年変動

各解析単位で最も精度が高いモデルについて、平年収量を加えたモデルを作成し、精度の比較を行った(表 2.4.1.1-5～表 2.4.1.1-8)。また、RMSE の年変動について、平年収量を加えたモデルとの比較を行った(図 2.4.1.1-13～図 2.4.1.1-16)。その結果、5km メッシュを除いて、平年収量を加えた効果は得られなかった。

表 2.4.1.1-5 1km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の結果

変数	RMSE
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	64.39
衛星データ+緯度経度+田植日出穂日(EVI前後3期間) + 平年収量	64.99

表 2.4.1.1-6 5km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の結果

変数	RMSE
衛星データ+緯度経度+田植日出穂日(EVI前後3期間)	57.21
衛星データ+緯度経度+田植日出穂日(EVI前後3期間) + 平年収量	57.11

表 2.4.1.1-7 10km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の結果

変数	RMSE
衛星データ+気象データ+田植日出穂日(EVI前後3期間)	46.28
衛星データ+気象データ+田植日出穂日(EVI前後3期間) + 平年収量	46.85

表 2.4.1.1-8 20km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の結果

変数	RMSE
衛星データ(EVI前後5期間)	38.26
衛星データ(EVI前後5期間) + 平年収量	39.14




図 2.4.1.1-13 1km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の年変動




図 2.4.1.1-14 5km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の年変動




図 2.4.1.1-15 10km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の年変動




図 2.4.1.1-16 20km メッシュで平年収量を追加した場合の収量予測モデルの RMSE の年変動

解析単位メッシュ内の田の割合が少ないデータが誤差要因と考え、田の割合が多いメッシュのみを対象としたモデルの精度を確認した。このために、各解析単位で最も精度が高いモデルについて、水田面積割合が多いメッシュを対象にランダムフォレストによる予測を行い、実測値との比較を行った。

1km メッシュで最も精度が高い「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデル」において、水田面積率 60%以上の 257 メッシュ (4964 メッシュ中) を対象にランダムフォレストにより予測を行い、実測値との比較を行った。散布図を図 2.4.1.1-17 に示す。このとき、RMSE は 64.41 となり、全メッシュを対象とした場合の RMSE の 64.39 をわずかに上回った。予測値と実測値との間には関係性が見られなかった。

5km メッシュで最も精度が高い「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日を組み合わせた収量予測モデル」において、水田面積率 20%以上の 58 メッシュ (277 メッシュ中) を対象にランダムフォレストにより予測を行い、実測値との比較を行った。散布図を図 2.4.1.1-18 に示す。このとき、RMSE は 51.25 となり、全メッシュを対象とした場合の RMSE の 57.21 を下回った。予測値と実測値との間には関係性が見られなかった。なお、5km メッシュでの田の割合が多いメッシュでは複数年の収量データがあるため、5km メッシュのほうが 1km メッシュよりも総データ数が多くなっている。

10km メッシュで最も精度が高い「EVI 前後 3 期間でスムージングした衛星データ+気象データ+田植日出穂日を組み合わせた収量予測モデル」において、水田面積率 10%以上の 37 メッシュ (82 メッシュ中) を対象にランダムフォレストにより予測を行い、実測値との比較を行った。散布図を図 2.4.1.1-19 に示す。このとき、RMSE は 39.94 となり、全メッシュを対象とした場合の RMSE の 46.28 を下回った。予測値と実測値との間には関係性が見られなかった。

20km メッシュで最も精度が高い「EVI 前後 5 期間でスムージングした衛星データの収量予測モデル」において、水田面積率 5%以上の 14 メッシュ (31 メッシュ中) を対象にランダムフォレストにより予測を行い、実測値との比較を行った。散布図を図 2.4.1.1-20 に示す。このとき、RMSE は 29.43 となり、全メッシュを対象とした場合の RMSE の 38.26

を下回った。予測値と実測値との間には関係性が見られなかった。




図 2.4.1.1-17 田の割合が多い 1km メッシュとした場合の収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-18 田の割合が多い 5km メッシュとした場合の収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-19 田の割合が多い 10km メッシュとした場合の収量予測モデルの予測値と実測値の散布図




図 2.4.1.1-20 田の割合が多い 20km メッシュとした場合の収量予測モデルの予測値と実測値の散布図

(2) 重回帰分析の結果

ランダムフォレストを用いた収量予測モデルの精度評価で 20km メッシュの時が最も精度が高くなったため、重回帰分析の解析単位として 20km を用いた。全ての変数を含めた「衛星データ+気象データ+緯度経度+田植日出穂日」の収量予測モデルについて、植生指数の EVI を前後 3 期間でスムージングしたものの RMSE は 39.13、前後 5 期間でスムージングしたものの RMSE は 39.36 となり、EVI を前後 3 期間でスムージングしたもののほうが精度は高くなったため、EVI を前後 3 期間でスムージングした「衛星データ+気象データ+緯度経度+田植日出穂日」の変数を用いることとした。

次にこれらの変数について、ランダムフォレストによる変数の重要度を算出した。その上位 12 位までの結果を表 2.4.1.1-9 に示す。表 2.4.1.1-9 の変数のうち、風速は収量との間に線形回帰の相関があるとは考えにくいため変数から除外した。その上で、作柄表示地帯(北部・南部・鹿行)をダミー変数として追加した。

そしてこれらの変数の VIF を算出した。VIF の最大は 2.44 となり、多重共線性の問題はないと考えられる。

そこで、これらの変数を説明変数、収量を目的変数として、ステップワイズ法により説明変数の選択を行った。その結果、「出穂日」、「平均気温」、「出穂日～約 1 か月後」、「EVIxSWR 約 1 か月前～出穂日」、「LST 約 1 か月前～出穂日」、「緯度」、「作柄表示地帯北部ダミー」、「作柄表示地帯南部ダミー」が除外された。ここでランダムフォレストの重要度が高かった「出穂日」がステップワイズ法により除外されたのは、ランダムフォレストは非線形に対して、重回帰分析は線形であり、「出穂日」は特定の日をピークにそれよりも早くても遅くても収量は少なくなる傾向にあると想定され、線形ではそれを表現できないためと考えられる。

選択した説明変数を用いた重回帰分析による偏回帰係数と標準偏回帰係数を表 2.4.1.1-10 に示す。偏回帰係数の値の大小は説明変数の単位や大きさに依存し、変数間の比較ができない。そのため、各説明変数について標準化を行うことで、説明変数の単位や大きさに関わらず変数間の比較ができるようにしたものが標準偏回帰係数である。表 2.4.1.1-10 より標準偏回帰係数は日照時間の約 2～1 か月前が最も大きく、次いで Band4 の出穂日～約 1 か月後となり、これらの変数が重要であることがわかった。

予測式の検証を行うために、交差検証法を用いて検証年を除いたトレーニング年で予測式を作成し、検証年で検証を行った。その結果、RMSE は 39.11 となり、機械学習で最も精度が高かった 20km メッシュでの「EVI 前後 5 期間でスムージングした衛星データの収量予測モデル」での RMSE38.26 を上回った。重回帰分析よりも機械学習のほうが精度が高い結果が得られた。重回帰分析における交差検証法による実測値と予測値の平均絶対誤差(MAE)は 29.76 となり、重回帰分析により平均で $\pm 29.76\text{kg}/10\text{a}$ の誤差で予測することができた。交差検証法による予測値と実測値の散布図を図 2.4.1.1-21 に示す。図 2.4.1.1-21 より、予測値と実測値との間に一定の関係性は見られたが、実測値の高いものと低いもので予測ができておらず、高い精度は得られなかった。

表 2.4.1.1-9 ランダムフォレストによる変数の重要度(上位 12 位まで)

変数	重要度
出穂日	0.065
日照時間 約2～1か月前	0.053
Band4 出穂日～約1か月後	0.048
風速 出穂日～約1か月後	0.042
平均気温 出穂日～約1か月後	0.034
EVlxSWR 約1か月前～出穂日	0.034
SWR 約1か月前～出穂日	0.032
風速 約2～1か月前	0.031
LST 約1か月前～出穂日	0.030
緯度	0.030
Band2 出穂日～約1か月後	0.030
平均気温 約1か月前～出穂日	0.029

表 2.4.1.1-10 重回帰分析による各説明変数の偏回帰係数と標準偏回帰係数

変数	偏回帰係数	標準偏回帰係数
Band2 出穂日～約1か月後	193.80	0.108
Band4 出穂日～約1か月後	715.74	0.165
SWR 約1か月前～出穂日	1.78	0.144
平均気温 約1か月前～出穂日	4.11	0.132
日照時間 約2～1か月前	7.49	0.257
作柄表示地帯・鹿行ダミー	7.79	0.073
(定数項)	242.82	0.000

決定係数: 0.1928 自由度調整済み決定係数:0.1801

データ数:388, 自由度:381




図 2.4.1.1-21 重回帰分析による予測値と実測値の散布図

(3) ほ場単位の水稲の収穫期前の 10a 当たり収量の予測結果

ほ場単位の水稲の収穫期前の 10a 当たり収量の予測として、9 月 15 日の収量予測を行った。

ランダムフォレストを用いた収量予測モデルの精度評価での各解析単位の収量予測モデルのうち、RMSE を用いて最も精度が高いモデルについて、全期間実測データを用いて解析単位ごとに予測を行い、その予測値を一番小さい解析単位である 1km メッシュ単位に変換した。各解析単位で最も精度が高いモデルは、1km メッシュでは、「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日」を組み合わせた収量予測モデル、5km メッシュでは「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日」を組み合わせた収量予測モデル、10km メッシュでは「EVI 前後 3 期間でスムージングした衛星データ+気象データ+田植日出穂日」を組み合わせた収量予測モデル、20km メッシュでは「EVI 前後 5 期間でスムージングした衛星データの収量予測モデル」となった。そして、それぞれの予測値を 1km メッシュ単位に変換し、1km メッシュでの予測値と実測値との RMSE を算出した。その結果、図 2.4.1.1-22 のようになり、メッシュが小さいほど精度が高くなり、その中でも 1km メッシュでの「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日」を組み合わせた収量予測モデルを用いた場合で最も精度が高くなった。そこで、9 月 15 日の予測のためのモデルとして、1km メッシュでの「EVI 前後 3 期間でスムージングした衛星データ+緯度経度+田植日出穂日」を組み合わせた収量予測モデルを用いることとした。

次に、この収量予測モデルを用いて、全期間実測データを用いて予測年を除いた年のデータをトレーニングデータとして、識別器を作成した。そして、9 月 15 日予測データを入力データとして、作成した識別器を用いてそれぞれの解析単位ごとの 9 月 15 日の収量予測を行った。

1km メッシュでの 9 月 15 日の予測結果として、2018 年の結果を図 2.4.1.1-23 に示す。図 2.4.1.1-23 より、2018 年の 9 月 15 日の予測値は北部で低く、中央部から南部で低い傾向が見られた。この傾向は変数に緯度が含まれ、トレーニングデータにおいても北部で低い傾向にあることから、このようになったと考えられる。

最後に 1km メッシュごとの予測値を筆ポリゴンと結び付け、各年の筆ポリゴンごとの 9 月 15 日の予測値を作成した。その 2018 年の結果を図 2.4.1.1-24 に示す。これにより、筆ポリゴンごとの 9 月 15 日の収量予測を行うことができた。




図 2.4.1.1-22 1km メッシュの実測値と 1km、5km、10km、20km メッシュの予測値との RMSE




図 2.4.1.1-23 9 月 15 日の 1km メッシュ単位の予測値(2018 年)




図 2.4.1.1-24 9 月 15 日の筆ポリゴン単位の予測値(2018 年)

4) 機械学習等を用いた収量予測のまとめ

ランダムフォレストを用いた収量予測モデルの精度評価を行った結果、解析単位に関わらず、気象データのみよりも衛星データのみ、もしくは衛星データを加えたほうが精度が高くなり、衛星データを収量予測に利用する可能性が確認できた。また解析単位が大きくなるほど、平均化され誤差が小さくなる傾向を確認した。

各解析単位について田の割合が多いメッシュのみを対象としてランダムフォレストで予測を行ったが、田の割合による影響は確認できなかった。これは、モデルを作るために必要なメッシュ数を得るために、十分に田の割合が高いメッシュのみで検証ができなかったためと考えられる。そのため、代表的なメッシュについて、目視判読による検証を予測結果の検証で行う。

各解析単位で最も精度が高かったモデルについて、平年収量を加えたモデルを作成し、精度の比較を行った結果、5km メッシュを除いて、平年収量を加えた効果は得られなかった。そのため、平年収量よりも予測に影響が大きいと考えられる衛星データの課題であるミクセルについて検証する必要があると考えられる。ミクセルとは mixed pixel の略であり、衛星画像の 1 つのピクセルに対し、スペクトル情報が 1 つしか得られないにも関わらず、1 つのピクセルの中に複数の土地被覆が混在している状態のことを指す。

重回帰分析により平均で $\pm 29.76\text{kg}/10\text{a}$ の誤差で予測することができた。しかし、予測値と実測値との間に一定の関係性は見られたが、実測値の高いものと低いものが予測できなかった。予測精度は重回帰分析よりもランダムフォレストのほうが高くなった。

水稻の収穫前の 10a 当たり収量の予測として、1km 単位で 9 月 15 日の予測を行い、筆ポリゴンと結び付けを行った。これにより、ほ場単位の水稲の収穫前の収量予測の方法を示せたと考えられる。

データ収集の課題として、収量データの坪刈りの位置情報は緯度経度の分単位であり、ほ場単位の粒度での実証と検証が困難であった。そのため、収量の情報と筆ポリゴンの位置情報等と結び付けを行うなど、坪刈りの位置情報の精度向上を行うことが考えられる。

収量予測に関する課題として、ランダムフォレストでは予測値と実測値との間に一定の関係性が見られたが、実測値が高い場合と低い場合にうまく予測できていない傾向が見られたため、ニューラルネットワークやサポートベクター回帰といった他の機械学習の手法を用いて予測を行い、比較検討することが考えられる。

現場実装に向けた課題と対応策を表 2.4.1.1-11 に示す。

表 2.4.1.1-11 現場実装に向けた課題と対応策

課題	対応策
衛星データ、気象データの収集および欠損値補完、データセット作成に専門知識を要する	・業者に委託していただく
出穂日情報が予測時に間に合わない可能性がある	・当年出穂日を予測していただく ・もしくは生育モデルである SIMRIW-RS の予測データを用いる
毎年識別器を更新する必要がある	・収量予測モデルを固定し、過去データと前年実測データを用いて識別器を更新する
衛星データが欠損することがある	・前後の期間のデータにより補完する ・長期間の欠損の場合は気象データのみ用いることを検討する
衛星データの入手が遅延することがある	・予測する時点で得られるデータを用いて予測を行う

衛星データ、気象データの収集および欠損値補完、データセット作成に専門知識を要するため、専門とする業者に委託することが想定される。

本実証調査の収量予測モデルでは出穂日の情報を利用しているが、これが予測時に間に合わない可能性があるため、当年の出穂日を予測する必要がある。また、本実証調査で生育モデルによる収量予測に用いている SIMRIW-RS により、出穂日の予測データが得られる。そのため、収量予測モデルと生育モデルとを融合させ、収量予測モデルの予測のために生育モデルの出穂日の予測データを用いることが想定される。

予測にはトレーニングデータから識別器を作成しているが、トレーニングデータは毎年追加されるため、識別器も毎年更新する必要がある。その都度使用する収量予測モデルの検討を行うと多くの労力と時間を要することになる。そこで、使用する収量予測モデルを固定し、過去データと前年実測データを用いて識別器を更新することが考えられる。

衛星データは欠損することがあり、その場合には前後の期間のデータにより補完することが考えられる。長期間の欠損の場合は気象データのみ用いることを検討する必要がある。

衛星データの入手が遅延することがあり、その場合には予測する時点で得られるデータを用いて予測を行うことが考えられる。

2.4.1.2 機械学習等を用いた収量予測結果の検証

(1) 9月15日予測値と実測値との検証

9月15日の1kmメッシュにおける予測値と実測値との関係の検証を行った。検証対象は、実測値のある1kmメッシュとした。9月15日の予測値と実測値との散布図を図2.4.1.2-1に示す。このときのMAEは50.96、RMSEは64.44となった。9月15日の収量は平均±50.96kg/10aの誤差で予測できたが、図2.4.1.2-1より、予測値と実測値との間に関係性は見られなかった。




図 2.4.1.2-1 9月15日の予測値と実測値の散布図

(2) 空間的な誤差要因の検証

衛星データと農地の区画情報(筆ポリゴン)の”田”を重ね合わせ、水田が含まれる衛星データのピクセルを用いているが、田周辺の土地被覆の影響を受けた衛星データが空間的な誤差要因と考えられる。解析単位における田以外の被覆の違いによる影響の確認するため、田周辺の土地被覆と誤差の関係を目視判読により確認した。

最小の解析単位である1kmで最も精度が高いモデルを用いて、9月15日の予測値と実測値との誤差を算出し、誤差が大きいメッシュや田面積割合が高いメッシュを目視で確認し、田周辺の土地被覆を確認により誤差要因を考察した。検証には収量が平均的な2018年を用いた。予測値が過大評価の2メッシュ、予測値が過小評価の2メッシュ、水田面積割合が高い2メッシュを対象とした。

2018年の収量データある1kmメッシュにおける水田面積割合を図2.4.1.2-2に、2018年における9月15日の予測値と実測値との誤差(予測値-実測値)を図2.4.1.2-3に示す。




図 2.4.1.2-2 2018 年の収量データある 1km メッシュにおける水田面積割合




図 2.4.1.2-3 2018 年における 9 月 15 日の予測値と実測値との誤差(予測値-実測値)

a. 予測値が過小評価となったメッシュの考察

予測値が過小評価となったメッシュの1例目として、3次メッシュコードが54401197のメッシュについて、空中写真を図2.4.1.2-4に示す。水田面積割合、2018年の9月15日の予測値、2018年の実測値、予測値と実測値との誤差の値を表2.4.1.2-1に示す。表2.4.1.2-1より、このメッシュでは予測値が161.5kg/10a 過大評価となっている。図2.4.1.2-4より、このメッシュでの田周辺のミクセル箇所として、森林、水路、畑が目視で確認でき、これらが誤差要因になっていると考えられる。




図 2.4.1.2-4 予測値が過大評価となったメッシュの1例目
(3次メッシュコード：54401197)の空中写真

表 2.4.1.2-1 予測値が過大評価となったメッシュの1例目
(3次メッシュコード：54401197)の各属性値

属性	値
水田面積割合	14 %
2018年の9月15日の予測値	532.5 kg/10a
2018年の実測値	371.0 kg/10a
2018年の誤差(予測値-実測値)	161.5 kg/10a

予測値が過大評価となったメッシュの2例目として、3次メッシュコードが54400016のメッシュについて、空中写真を図2.4.1.2-5に示す。水田面積割合、2018年の9月15

日の予測値、2018 年の実測値、予測値と実測値との誤差の値を表 2.4.1.2-2 に示す。表 2.4.1.2-2 より、このメッシュでは予測値が 111.0 kg/10a 過大評価となっている。図 2.4.1.2-5 より、このメッシュでの田周辺のミクセル箇所として、森林、水路、人工構造物が目視で確認でき、これらが誤差要因になっていると考えられる。




図 2.4.1.2-5 予測値が過大評価となったメッシュの 2 例目
(3 次メッシュコード: 54400016)の空中写真

表 2.4.1.2-2 予測値が過大評価となったメッシュの 2 例目
(3 次メッシュコード: 54400016)の各属性値

属性	値
水田面積割合	16%
2018 年の 9 月 15 日の予測値	482.0 kg/10a
2018 年の実測値	371.0 kg/10a
2018 年の誤差(予測値-実測値)	111.0 kg/10a

b. 予測値が過小評価となったメッシュの考察

予測値が過小評価となったメッシュの 1 例目として、3 次メッシュコードが 54400151 のメッシュについて、空中写真を図 2.4.1.2-6 に示す。水田面積割合、2018 年の 9 月 15 日の予測値、2018 年の実測値、予測値と実測値との誤差の値を表 2.4.1.2-3 に示す。表 2.4.1.2-3 より、このメッシュでは予測値が 126.4kg/10a 過小評価となっている。図 2.4.1.2-6 より、このメッシュでの田周辺のミクセル箇所として、森林、水路、畑、人工

構造物が目視で確認でき、これらが誤差要因になっていると考えられる。




図 2.4.1.2-6 予測値が過小評価となったメッシュの 1 例目
(3 次メッシュコード: 54400151)の空中写真

表 2.4.1.2-3 予測値が過小評価となったメッシュの 1 例目
(3 次メッシュコード: 54400151)の各属性値

属性	値
水田面積割合	4 %
2018 年の 9 月 15 日の予測値	528.6 kg/10a
2018 年の実測値	655.0 kg/10a
2018 年の誤差(予測値-実測値)	-126.4 kg/10a

予測値が過小評価となったメッシュの 2 例目として、3 次メッシュコードが 54406452 のメッシュについて、空中写真を図 2.4.1.2-7 に示す。水田面積割合、2018 年の 9 月 15 日の予測値、2018 年の実測値、予測値と実測値との誤差の値を表 2.4.1.2-4 に示す。表 2.4.1.2-4 より、このメッシュでは予測値が 137.1kg/10a 過小評価となっている。図 2.4.1.2-7 より、このメッシュでの田周辺のミクセル箇所として、人工構造物が目視で確認でき、これらが誤差要因になっていると考えられる。




図 2.4.1.2-7 予測値が過小評価となったメッシュの 1 例目
(3 次メッシュコード: 54406452)の空中写真

表 2.4.1.2-4 予測値が過小評価となったメッシュの 1 例目
(3 次メッシュコード: 54406452)の各属性値

属性	値
水田面積割合	36 %
2018 年の 9 月 15 日の予測値	551.9 kg/10a
2018 年の実測値	689.0 kg/10a
2018 年の誤差(予測値-実測値)	-137.1 kg/10a

c. 水田面積割合が高いメッシュの考察

水田面積割合が高いメッシュの 1 例目として、3 次メッシュコードが 53406155 のメッシュについて、空中写真を図 2.4.1.2-8 に示す。水田面積割合、2018 年の 9 月 15 日の予測値、2018 年の実測値、予測値と実測値との誤差の値を表 2.4.1.2-5 に示す。表 2.4.1.2-5 より、このメッシュでは予測値が実測値よりも 61.9 kg/10a 小さくなった。図 2.4.1.2-8 より、このメッシュは水田がほとんどを占めており、ミクセルの影響はほとんどないと考えられる。




図 2.4.1.2-8 水田面積割合が高いメッシュの 1 例目
(3 次メッシュコード: 53406155)の空中写真

表 2.4.1.2-5 水田面積割合が高いメッシュの 1 例目
(3 次メッシュコード: 53406155)の各属性値

属性	値
水田面積割合	89 %
2018 年の 9 月 15 日の予測値	537.1 kg/10a
2018 年の実測値	599.0 kg/10a
2018 年の誤差(予測値-実測値)	-61.9 kg/10a

水田面積割合が高いメッシュの 2 例目として、3 次メッシュコードが 54391798 のメッシュについて、空中写真を図 2.4.1.2-9 に示す。水田面積割合、2018 年の 9 月 15 日の予測値、2018 年の実測値、予測値と実測値との誤差の値を表 2.4.1.2-6 に示す。表 2.4.1.2-6 より、このメッシュでは予測値が実測値よりも 4.9 kg/10a 小さくなり、高い精度で予測ができています。図 2.4.1.2-9 より、このメッシュは水田がほとんどを占めており、ミクセルの影響はほとんどないと考えられる。




図 2.4.1.2-9 水田面積割合が高いメッシュの 2 例目
(3 次メッシュコード: 54391798)の空中写真

表 2.4.1.2-6 水田面積割合が高いメッシュの 2 例目
(3 次メッシュコード: 54391798)の各属性値

属性	値
水田面積割合	87 %
2018 年の 9 月 15 日の予測値	539.9kg/10a
2018 年の実測値	535.0 kg/10a
2018 年の誤差(予測値-実測値)	-4.9 kg/10a

d. 空間的な誤差要因の検証のまとめ

誤差が大きいメッシュや田面積割合が高いメッシュを目視で確認した結果、誤差が大きい箇所では、田の面積割合が低く、森林、河川、畑、人工構造物とのミクセルが顕著であることが分かった。田の面積割合が高い箇所では、ミクセルの影響は小さく、誤差が小さい傾向にあることが分かった。そのため、衛星データの空間分解能を上げ、ミクセルの影響を抑えることで、精度が向上すると考えられる。

(3) 収量予測結果の検証のまとめ

9 月 15 日の予測値と実測値との関係の検証を行った結果、9 月 15 日の収量は平均 $\pm 50.96\text{kg}/10\text{a}$ の誤差で予測できたが、予測値と実測値との散布図からは予測値と実測

値との間に関係性は見られなかった。そのため、今回の手法、モデルの改善が必要であると考えられる。今回は機械学習の手法としてランダムフォレストを用いたが、ニューラルネットワークやサポートベクター回帰といった手法との比較評価を行うことが考えられる。また、衛星データや気象データでは捉えられない病気等による不作がある。このような不作については付随情報によりデータのふり分けを行い、病気等による不作地域やデータを除いてモデルの構築を行い、予測についてもこのような地域やデータを除いて行うことで精度向上を図ることが考えられる。

空間的な誤差の検証では、目視判読による検証により、衛星データの空間分解能を上げ、ミクセルの影響をおさえることで、精度が向上する傾向を確認した。そのため、精度向上を図るためには、空間分解能が高く、天候の影響を考慮し、観測頻度が高い PlanetScope のような衛星データの活用が有効と考えられる。

2.4.1.3 機械学習等を用いた収量予測結果を踏まえた現場実装の可能性の検討

「スマート農業における、収量データに基づく戦略的・安定的な農業経営の実現への寄与」と「水稻作況調査の効率化」に向けた検討を行った。

1. 今回検討した手法は、上記目的に向けた手法として有効であり、継続的な手法の開発・改良を行うことが望ましい。
2. 更に精緻な手法として構築するためには、トレーニングデータとなる収量データが筆ポリゴンと結びついた位置精度の高いデータを用いてモデルの構築を行うことが望ましい。
3. 高空間分解能、高頻度観測が可能な PlanetScope のような衛星データの利用により精度向上が期待できる。
4. 別途事業（「人工知能（AI）を活用した筆ポリゴン変化抽出手法等を用いた筆ポリゴン作成業務」や「令和2年度画像解析による農地の区画ごとの作付状況の把握手法及び水稻単収把握手法の開発・調査等業務」の作付状況の把握手法の開発など）で利用される予定の PlanetScope を効率よく利用する方策が考えられる。
5. 「令和2年度画像解析による農地の区画ごとの作付状況の把握手法及び水稻単収把握手法の開発・調査等業務」の作付状況の把握手法の開発では、時系列データを用いるため、今回検討した手法に適用できる可能性がある。
6. 「人工知能（AI）を活用した筆ポリゴン変化抽出手法等を用いた筆ポリゴン作成業務」の場合、夏期の一時期の画像を利用することになるため、別途、利用方法を検討する必要がある。
7. 例えば、田周辺の土地被覆分類を行い、空間分解能が低い衛星データ（画素内）における森林、河川、畑、人工構造物の面積割合から影響度を考慮するモデルを構築する方法などが考えられる。

2.4.2 生育モデルを用いた収量予測

収量予測プロセスモデルとして東北大学本間教授が開発した SIMRIW-RS (Homma et al., 2017) を用いた。SIMRIW-RS は水稻の気象生産力や気候変動影響評価に定評のある SIMRIW (Horie, 1987; Matthews et al., 1997; 田中ら 2011) をもとに、リモートセンシングの入力を前提に開発したものである。水稻のジャポニカやインディカ、さらに在来品種や改良品種であっても適用可能であり、低肥沃から多肥栽培までの栽培環境での検証が行われている (図 2.4.2-1; Homma et al., 2017)。主に生産性に関する情報が乏しいラオスやタイ、インドネシアなどの東南アジアを中心に適用が試みられてきたが (Maki et al., 2017; Raksapatcharawong et al., 2020; Homma et al., 2019)、盛岡や仙台において農事組合法人への栽培支援に向けた検討も行われ始めている (牧ら 2016; 本間ら 2018)。




図 2.4.2-1 SIMRIW-RS による (左) 地上部乾物重と (右) 収量の予測値と実測値の関係。多様な 6 品種を対象に土壌肥沃度の異なる 5 環境で検証を行った (Homma et al., 2017)。

SIMRIW-RS においてはベースとして用いる品種パラメータやほ場パラメータはあるものの、リモートセンシングデータをもとにそれらのパラメータを最適化して、生育評価並びに収量予測を行う (図 2.4.2-2; 牧ら 2016)。したがって最小限必要とする入力データは、評価対象地の緯度 (日長時間の計算に使用)、植え付け日、平均気温、日射量 (もしくは日照時間)、さらに最低 2 回のリモートセンシングデータに基づく生育評価値である。しかしながら情報は多ければ多いほどより対象に即した推定が可能である。例えばインドネシアの適用においては衛星データから移植日を推定し、NDVI を 4 回ほ場ごとに評価することにより 250ha、6,000 筆のほ場の生育評価を行った (Homma et al., 2019)。




図 2.4.2-2 SIMRIW-RS によるパラメータ調整の一例（牧ら 2016）。

栽培支援向けは主に通称ドローンとよばれる小型の UAV (Unmanned Aerial Vehicle) の利用を想定して研究が進められているが（牧ら 2016）、現状では 100ha 規模の大規模な農業経営体への適用が難しく、定期的なデータ収集も困難であることから、実証実験では衛星データを利用した検討を行った。また収量推定にあたり、実装の前に精度の検証が必要なため、現場への適用を目指した逐次推定方式（牧ら 2016）ではなく、田植直後から収穫前までのデータを用いて収量推定を行った。

2.4.2.1 生育モデルを用いた収量予測の実証実験

1) 使用データ

衛星データは Terra/MODIS と Aqua/MODIS の NDVI と LAI を用いた。MODIS の NDVI と LAI を比較すると LAI の方が生育に合わせた変化が明瞭であった（図 2.1.1.1-1）。LAI は 5 月や 6 月に値が低く、8 月に最大値を示し 9 月に再び低下する地点が多かった。一方 NDVI は 5 月や 9 月に低下する傾向を示すものの、7 月や 8 月の値との差が明瞭ではなかった。また一般的に NDVI は 7 月や 8 月にほ場が水稻群落で被覆されると飽和値を示すと考えられるが、ほ場間で差が大きかった。図 2.4.2.1-1 に示した例では、ほ場番号 60 と 62（以下ほ場番号は茨城県筆成績一覧表における通し番号を示す）においては LAI と NDVI とともに生育に合わせた変化を示したが、ほ場番号 63 においては LAI は生育に合わせた変化を示したものの NDVI はほぼ一定値を示した。また、ほ場番号 59 と 64 においては NDVI と LAI とともにほぼ一定もしくは大きな変動を示し、変化は明瞭ではなかった。




図 2.4.2.1-1 使用データの例（2013 年）。（上）NDVI、（下）LAI の水稻の生育期間の推移を示す。凡例の数字は茨城県筆成績一覧表における通し番号（ほ場番号）を示す。DOY : Days of Year、x 軸の目盛はおおよそ 5～9 月に相当する。

気象データは NDVI と LAI の抽出地点の緯度経度をもとに最寄りのアメダスを選択して用いた。日ごとの最高、最低、平均気温と日照時間を使用した日照時間から日射量を推定した（Angstrom）。日長時間はアメダスの観測所の緯度から計算した。

2) 使用パラメータと最適化方法

実証実験ではコシヒカリ栽培ほ場に限定したため、既存の品種パラメータを用いた。発育パラメータは堀江・中川（1990）のものを使用し、LAI に対する乾物生産や収量性に関しては仙台の農家水田にて得られた値を用いた。品種パラメータを固定し、SIMRIW-RS により計算される LAI や NDVI と衛星データに基づく LAI や NDVI との誤差の二乗が最小になるようには場パラメータを最適化した。誤差の二乗の最小化には網羅的探索法の一つである改良 SIMPLEX 法を用いた。最適化されるほ場パラメータは初期の葉面積成長速度を左右する土壌肥沃度に関連するパラメータとその減衰率（保肥力等に関係）に関連するパラメータである。LAI から NDVI への変換は葉群と地面の受光率と反射率から Hashimoto et al.（2020）を参考に推定した。

3) 実験結果

(1) 発育予測

出穂日や成熟日などの発育は緯度によって決まる日長と、堀江・中川（1990）によるパラメータから求められる。出穂日は地点間で誤差はみられるものの、実測値と予測値がほぼ一致した。一方成熟日の予測は実測の収穫日＋約5日であった。




図 2.4.2.1-2 SIMRIW-RS における（上）出穂日と（下）成熟日の予測日と実測の出穂日と収穫日の関係。2019 年の推定例を示した。DOY=213 は 7 月 1 日、DOY=244 は 9 月 1 日を示す。

成熟日と収穫日の差異は堀江・中川（1990）における成熟日の評価と、収穫調査実施日の際に基づく可能性もあり、修正の必要性の有無に関しては詳細な検討が必要と考えられる。モデルの構造的には出穂日以降葉面積が減少し、光合成に相当する日射乾物変換効率も低下するため、出穂日から成熟日までの推定誤差が与える影響は比較的小さいと考えられる。したがって本実証実験では発育に関するパラメータを変更せずに実証実

験を継続した。

(2) NDVI を用いた最適化

図 2.4.2.1-1 で示したほ場を例として示すと、MODIS による NDVI が生育に応じた変化を示すほ場では、SIMRIW-RS による NDVI の推定値が MODIS による NDVI の推移をよく説明した (図 2.4.2.1-3)。一方 MODIS の NDVI がほぼ一定値を示す場合は、NDVI の飽和値で解が収束してしまうため、最適化がうまくいかなかった。





図 2.4.2.1-3 NDVI を用いた最適化例。MODIS による NDVI がほぼ一定値を示したほ場（上、ほ場番号 59）と、水稻の生育に伴う変化を示したほ場（下、ほ場番号 62）。赤線：SIMRIW-RS による推定値。青印：MODIS のよる NDVI。2003 年の例。




図 2.4.2.1-4 NDVI を用いた収量の予測値と実測値の関係。(上)2003 年、(下) 2019 年の例を示した。

図 2.4.2.1-3 のほ場番号 59 において予測収量が 0 となるのは、移植直後から NDVI が飽和すなわち群落が完全被覆状態と推定され、そのような状態は過繁茂状態となるため倒伏を想定した因子により収量が制限されるためである。またほ場番号 62 では NDVI が飽和値に達しておらず、そのため収量が過少評価された。これらの影響のため収量の実測値と推定値を比較すると、推定値は全体として過小評価する傾向にあった（図 2.1.1.1-4）。今回の実証実験では SIMRIW-RS における NDVI の予測は、LAI の予測に基づき理論的な NDVI を推定したが、NDVI は衛星の違いや解像度などにより系統誤差が生じるのがわかっている。したがって LAI と NDVI の関係を MODIS のデータに基づいて評価しなおすことにより、収量の推定誤差を小さくすることは可能である。しかしながらほ場間で 7 月 8 月の NDVI 値が大きく異なり、NDVI の飽和値の設定により予測収量が大きく異なるため、今回の実証実験ではこれ以上の検討は行わないことにした。

(3) LAI を用いた最適化

LAI を用いた最適化においても NDVI を用いた最適化と同様に、LAI がほぼ一定値を示すほ場においては生育初期から LAI が大きく推定され、LAI が生育に応じた変化を示すほ場においては LAI の推移を比較的良好に推定できた（図 2.4.2.1-5）。




図 2.4.2.1-5 LAI を用いた最適化例。MODIS による LAI がほぼ一定値を示したほ場（上、ほ場番号 59）と、水稻の生育に伴う変化を示したほ場（下、ほ場番号 62）。赤線：SIMRIW-RS による推定値。青印：MODIS による LAI。2003 年の例。

MODIS の LAI が一定値を示すほ場においては、生育初期から比較的大きな LAI を示すため、収量が過大に評価される傾向にあったが、NDVI を用いた推定とは異なり、推定収量が 0 となったほ場は少なかった。一方 LAI が生育に応じた変化を示すほ場においては実測値と予測値が一致するほ場も見られた。ほ場ごとの収量の実測値と推定値を比較すると一部で大きく外れる点はみられたものの、ある程度の関係性はみられた（図 2.4.2.1-6）。

以上のことより、次節においては LAI を用いた最適化に基づく予測収量に基づいて、

収量予測結果の検証を行った。




図 2.4.2.1-6 LAI を用いた収量の予測値と実測値の関係。(上)2003 年、(下) 2019 年の例を示した。

2.4.2.2 生育モデルを用いた収量予測結果の検証

(1) 年次間差と地点間差の検証

図 2.1.1.1-6 では実測の収量に対して予測収量が大きく外れるほ場が示された。また、2019 年では実測と予測の収量がほぼ 1 : 1 なのに対し、2003 年では推定収量が過小評価となっている。そこで予測収量と実測収量を年および地点で平均し、それぞれの傾向を確認した(図 2.4.2.2-1)。地点については収量予測の時に使用した最寄りのアメダス観測地点ごとに集計した。

年平均で比較した収量の実測値と予測値には明らかな外れ値はなく、有意な相関を示した($r=0.56$)。2003 年は全国的に冷夏であり実測収量は例年と比較しても低かったが、予測収量はそれよりも低かった。それ以外の過小評価や過大評価の原因は明らかではなかった。

アメダス観測地点ごとに平均した場合、実測値と予測値に有意な関係はみられなかった。大子、常陸大宮、北茨城、古河などでは実測値に対して予測値が大きく外れた。




図 2.4.2.2-1 LAI を用いた収量の予測値と実測値における、(上) 観測年ごとの平均値と (下) アメダス観測地点ごとの平均値。




図 2.4.2.2-2 アメダスの観測地点の（上）大子および（下）つくばの気象データを用いて予測したほ場における収量の予測値と実測値の年平均値の関係。

予測値が大きく外れた大子などにおいて年平均値を比較すると、明瞭な外れ値を示す年があり、それにより実測値と予測値の関係が一定しないと考えられた(図 2.4.2.2-2)。こうした明瞭な外れ値は図 2.1.1.1-5 で示すような、MODIS の LAI がほぼ一定値を示すことなどによっていた。一方、観測地点ごとの平均値において $y=x$ 付近に位置したつくばなどにおいては、明瞭な外れ値が少なく、年平均値で比較すると実測値と予測値に有意な関係性がみられた(図 2.4.2.2-2)。

(2) 気象要因による変動と MODIS の LAI に起因する変動の検証

上述した年次間差と地点間差を検討するために、単一の LAI データセットを用意し、各年のアメダス観測データを用いて収量予測を行った。すなわち単一の LAI データセットを用いた予測収量は、気象要因によってのみ変動すると考えられ、単一の LAI データセットとメッシュごとの LAI を用いた予測収量の差異は、MODIS の LAI に起因する変動と考えられる。単一の LAI データセットとして、2019 年のつくばでの気象においてその年の平均収量 (507kg/10a) を示すように設定したデータセットを用意した。




図 2.4.2.2-3 単一の LAI データセットを用い、アメダスの観測データに基づき予測した収量と実測収量との関係。(上) 観測年ごとの平均値、(下) アメダス観測地点ごとの平均値。

単一の LAI データセットを用い、アメダスの観測データに基づき予測した収量は、実測収量と有意な相関を示し、収量の年次変動の一部は日射と気温の気象要因によって説明しうると考えられた (図 2.4.2.2-3)。また、2019 年だけでなく、2003 年や 2005 年などもほぼ $y=x$ の直線状に並び、シミュレーションモデルによる推定が妥当であると考えられた。一方、2012 年は実測収量の 547 kg/10a に対し、推定収量が 691 kg/10a と 100 kg/10a 以上の過大評価となり、その他にも過大評価の年があることから気象要因だけでは説明できない生産変動もあることが確認できた。

同様に予測収量をアメダス観測地点ごとに集計すると、こちらも実測収量と有意な相関を示し、収量の地点間差の一部は気象要因によって説明しうると考えられた。しかしながら下妻、下館、笠間、古河、大子が $y=x$ 上に並ぶのに対し、その他の地点は過大評価傾向にあり、同等の気象生産力に対して実際の収量には地域間差があることも明らかとなった。

単一の LAI データセットを用いた図 2.4.2.2-3 とメッシュごとの LAI データセットを用いた図 2.1.1.2-1 を比較すると、図 2.4.2.2-4 のように示された。観測年ごとに集計した場合、単一の LAI データセットを使用した結果と比較すると、メッシュごとの LAI データセットの使用により RMSE は 67 kg/10a から 51 kg/10a に減少するものの、決定

係数 R^2 も 0.36 から 0.32 に小さくなっていた。したがってメッシュごとの LAI データセットの利用は、収量の予測精度において全体的な改良には結びついていないと考えられた。しかしながら 2012 年などの過大評価傾向は小さくなるため、年次変動性の予測改善において一定の効果があると考えられた。

一方アメダス観測地点ごとに集計した場合、2.4.2.2 (1) で述べたように、大子、常陸大宮、北茨城、古河ではメッシュごとの LAI データセットを用いて予測することによって、実測収量からの乖離が大きくなった。しかしながらそれ以外の地点では収量差の乖離が小さくなり、メッシュごとの LAI データセットによる補正がうまく働いたと考えられた。以上のことよりメッシュごとの LAI データセットにおいて、図 2.4.2.2-4 (上) で示されるような水稻生育を反映していない地点を除去することが必要と考えられた。




図 2.4.2.2-4 単一の LAI データセットを用いて予測した収量 (図 2.4.2.2-4) とメッシュごとの LAI データセットを用いて予測した収量 (図 2.4.2.2-1) の比較。(上) 観測年ごとに平均、(下) アメダス観測地点ごとに平均し、実測の収量に対して示した。

(3) MODIS の LAI データセットの地点選択に関する検討

上述したように SIMRIW-RS の収量予測における誤差の一因は MODIS の LAI データセットにおいて、水稻の生育を反映しないような値を示す地点が含まれていることと考えら

れた。主観的に生育を反映する地点と反映しない地点を選択することは可能であるものの、中間的な傾向を示す地点もありその判断は難しい。そこで代表的な地域としてつくば市大形付近（36.14N、140.13E、図 2.4.2.2-5）を選択し、地点選択の方法について検討を行った。




図 2.4.2.2-5 解析対象地域（つくば市大形付近、36.14N、140.13E）における、筆ポリゴンに基づく水田分布と解析対象メッシュの位置。




図 2.4.2.2-6 解析対象地域（図 2.4.2.2-5）における収量の実測値と予測値の関係、2003 年から 2019 年までのほ場ごとの値を、最適化の際の RMSE 値で分けて示した。

LAI データセットが水稻の生育に伴った変化を示すかどうかについては、第一に最適化の際の LAI の RMSE で判断できると考えられる。例えば図 2.4.2.1-3 (上) のほ場番号 59 で MODIS の LAI がほぼ一定値を示す場合、LAI の RMSE は 1.9 である。一方同図 (下) のほ場番号 62 で MODIS の LAI が生育に応じた変化を示す場合、LAI の RMSE は 0.9 である。ほ場番号 62 においては DOY217 と 225 において大きな外れ値を示すため、図における最適化の印象以上に RMSE が大きくなる。そうした問題点はあるものの LAI の RMSE は、LAI が生育に応じた変化を示すかどうかの判断材料の一つになると考えられる。実際に対象地域においては予測収量と実測収量の残差は LAI の RMSE と有意な相関を示し ($R=0.44$)、LAI の RMSE が小さい地点では収量予測がうまくいく傾向を示した。しかしながら LAI の RMSE で地点を分類し、予測収量と実測収量の関係を示すと、それだけでは不十分であると考えられた (図 2.4.2.2-6)。

茨城県筆成績一覧表で示されるほ場位置は分単位の緯度経度であり、ほ場の正確な位置が特定されるわけではない。また、山間の水田が調査対象として選択されている場合もある。そのため図 2.4.2.2-6 で示されるように緯度経度情報で抽出されたメッシュは水田面積を多く含むものから少なく含むものまで多様である。水田面積割合が低いメッシュはその他の対象物の影響で LAI の誤差要因になると考えられる。そこで解析対象メッシュにおける水田面積割合でほ場を分類し、実測値と予測値の関係を示すと図 2.1.1.2-8 のようになった。水田面積割合の高いメッシュが少なく、はっきりとした傾向を検出することができず、これ以上の検討は難しいと考えられた。




図 2.4.2.2-7 解析対象地域 (図 2.4.2.2-5) における収量の実測値と予測値の関係。2003 年から 2009 年までのほ場ごとの値を、解析対象メッシュにおける水田面積割合で分けて示した。

2.4.2.3 生育モデルを用いた収量予測結果を踏まえた現場実装の可能性の検討

以上のように MODIS の NDVI と LAI を用いて、プロセスモデル SIMRIW-RS による収量予測を行った。本実証実験では 2003 年からのデータ蓄積があり、定期的なデータ取得が可能である MODIS を衛星データ源として利用したが、図 2.4.2.2-5 に示すとおり実際の水田に対し解像度が粗く、ほ場単位の推定は難しいと考えられた。例えば図 2.4.2.2-7 の場合、予測収量が示すのは 500m メッシュ全体の生産性の動向なのに対し、実測収量は評価地点の収量であり、地域の生産性を反映しているとは言い難い。対象点数が多ければ図 2.1.1.2-7 のように一定の傾向を示すと考えられるが、本実証実験では具体的な現場実装の可能性を示すには至らなかった。ほ場単位での適用性を検討するためには筆ポリゴンでの位置の特定と、それに見合った解像度の衛星データが必要であると考えられる。本実証実験の支援者である東北大学農学研究科作物学研究室では仙台沿岸部の農家ほ場を対象に Sentinel-1/2 を利用した水稻の生産性把握に取り組んでいるが（細沼ら 2021）、そうした取り組みの一般化が必要であると考えられる。

解析対象をマクロにすると、例えば本実証実験におけるアメダスの観測地点ごとのように、SIMRIW-RS は日射量と気温の気象要因に起因する変動を評価し、限定的ではあるもののメッシュごとの LAI による予測精度の改善可能性を示すことができた。したがって評価対象地域を絞り込み、その地域の水稲の生育を反映するようなメッシュを特定できれば、生産性評価が可能であると考えられる。精度については本実証実験では収量の RMSE が 50 kg/10a 以上ではあったものの、既存のパラメータを使用した結果であり、現状に即した補正により精度を改善することは可能である。年次変動性の解析からは実測収量の低い環境では過小評価、実測収量の高い環境では過大評価の傾向があったことから、日射や温度の影響を過大に見積もりすぎていると考えられる。それらには品種特性の他に施肥や水などの栽培管理の影響や、土壌の養分の供給力や保肥力などが関係していると考えられ、実際の栽培状況・環境に即した補正が必要である。その反面データに応じた補正はいくらでも可能であり、過適合が生じる可能性があるため、本実証実験では検証を行わなかった。現場実装を行うための補正は対象や目的を明確にして行う必要がある。

現在農家ほ場レベルにおけるスマート農業には衛星に加えてドローンに代表される UAV の利用が検討されている（牧ら 2016、橋本ら 2021）。しかしながら現状の UAV 機器で評価できるのは十数 ha 程度であり、スマート農業の本格的導入が検討されている 100ha 規模の農業経営体での利用は簡単ではない。一方衛星を利用した評価ではほ場内の生産性変動など詳細な評価は難しい。したがって両者の利点を組み合わせ、衛星を利用したベースとなる評価に UAV を利用したダウンスケールが必要であると考えられる。また、現在主流のリモートセンシングによる評価は基本的に一時期の情報に基づいて行われるが、水稻の生育は日々の積み重ねであり経時的な変化などの時間軸も考慮した評価が必要である。したがって本実証実験のようにシミュレーションモデルを利用した評価が今後ますます進展すると考えられる。一方データの利用法としては機械学習に基づく予測も有効と考えられるが、機械学習は因果関係を詳細に記述できるわけではなくデータの範囲内の事象を確率的に示すことになる。さらに過適合の排除などについては課題も多い。したがって例えば本実証実験の場合、対象とするデータ選択には機械学習を利用し、シミュレーションモデルに基づいて予測を行うなどのそれぞれの長所を生かした融合が必要であると考えられる（本間ら 2019）。

2.5 打ち合わせ会議等の開催

本業務の進捗を報告・確認するために、当財団は月1回程度担当部署と打ち合わせ会議を行い、事業の成果や課題を示すとともに、提言を受けた。打ち合わせ会議の開催一覧を表2.5-1に示す。

表 2.5-1 打ち合わせ会議一覧

回	開催日	内容
1	2020年7月16日(木)	(1)実施概要について (2)確認事項 (対象地域について、検討委員について、第1回検討会の日程及び議題について、使用する衛星について、ほ場の最終収量の入手時期について)
2	2020年8月31日(月)	(1)調査対象地域の選定 (2)センシングデータの選定・活用方法 (3)収量予測モデルの選定 (4)第1回検討会の時期及び開催方法について
3	2020年10月2日(金)	(1)第1回検討会の議題及び報告内容について (2)業務進捗状況について
4	2020年11月6日(金)	(1)業務進捗状況について
5	2020年11月30日(月)	(1)業務進捗状況について (2)第2回検討会の時期について

参考文献

- 本間香貴, 牧雅康, 廣岡義博. (2012). 稲の生育・収量予測モデルの広域評価型への展開. In 日本作物学会講演会要旨集 第233回日本作物学会講演会 (pp. 410-410). 日本作物学会.
- Homma, K., Maki, M., Hirooka, Y. (2017). Development of a rice simulation model for remote-sensing (SIMRIW-RS). Journal of Agricultural Meteorology, 73(1), 9-15.
- 本間香貴, 牧雅康, 橋本直之. (2018). リモートセンシングとシミュレーションモデルの融合による栽培支援の展望. 作物研究, 63, 43-48.
- Horie, T. (1987). A model for evaluating climatic productivity and water balance of irrigated rice and its application to Southeast Asia. Japanese Journal of Southeast Asian Studies, 25(1), 62-74.
- Homma, K., Horie, T., (2009). The present situation and the future improvement of fertilizer applications by farmers in rainfed rice culture in Northeast Thailand. In Elsworth, L.R., Paley, W.O. (Eds.) Fertilizers: Properties, Applications, and Effects. Nova Science Publishers, New York, 147-180.
- 金子大二郎. (2006). 衛星を用いた光合成型モデルによる日本の水稻作況指数の推定. 日本リモートセンシング学会誌, 26(3), 202-212.
- 金子大二郎, 森脇祐太. (2008). 光合成・不稔型穀物生産モデルによる水稻のCO₂固定速度の季節変化と単位面積収量の推定. システム農学, 24(2), 93-102

- Son, N. T., Chen, C. F., Chen, C. R., Chang, L. Y., Chiang, S. H. (2016). Rice yield estimation through assimilating satellite data into a crop simulation model. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 8.
- 田中圭, 近藤昭彦. (2016). 小型マルチコプターを用いた近接リモートセンシングによる水稻生育マップの作成. *日本リモートセンシング学会誌*, 36(4), 373-387
- 河野達也, 長澤良太. (2019). Sentinel-2 画像を用いた水田の塩類化土壌の抽出と稲作収量との関係. *システム農学*, 35(2), 25-32
- 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(4), 277-286
- 濱侃, 田中圭, 望月篤, 新井弘幸, 平田俊之, 八幡竜也他 (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(2), 68-82.
- 竹澤邦夫, 韓成一, 二宮正士, 本郷千春, 徳井和久, 伊東明彦, 竹島敏明. (2007). 衛星データによる水稻収量推定における重み付き回帰の利用. *システム農学*, 23(3), 251-261.
- 吉田圭吾, 高山泰一, 福原弘太郎, 内田敦, 関根秀真, 鹿志村修. (2012). スパース正則化を用いたハイパースペクトルデータの解析 インドネシア水田地帯における水稻生育状況診断および収量予測への適用. *日本リモートセンシング学会誌*, 32(5), 287-299.
- 橋本直之, 齋藤裕樹, 山本修平, 牧雅康, 本間香貴 (2021) 農家水稻圃場における UAV 空撮画像を用いた追肥に伴う葉面積変化の検出. *日作紀* 90(2), 219-229.
- Homma, K. (2019) Rice growth evaluation by simulation model with remote sensing. *International Conference on Sustainability Science and Management. The 9th Indonesia Japan Joint Scientific Symposium*. Nov. 14-15, 2019. Bali, Indonesia.
- 細沼航平, 石橋多郎, 伊藤壘人, 齋藤裕樹, 橋本直之, 山本修平, 牧雅康, 本間香貴 (2021). Sentinel-1/2 の時系列衛星データを用いた仙台沿岸部農家圃場における水稻の生育評価に関する研究. 第 251 回日本作物学会講演会 2021 年 3 月 29・30 日, 京都 (Online)
- 牧雅康, 本間香貴, 沖一雄. (2016). 作物モデルと UAV 画像を用いた LAI 推定と広域展開の可能性. *農業農村工学会誌*, 84(9), 757-760.
- Maki, M., Sekiguchi, K., Homma, K., Hirooka, Y., Oki, K. (2017). Estimation of rice yield by SIMRIW-RS, a model that integrates remote sensing data into a crop growth model. *Journal of Agricultural Meteorology*, 73(1), 2-8.
- Matthews, R. B., Kropff, M. J., Horie, T., Bachelet, D. (1997). Simulating the impact of climate change on rice production in Asia and evaluating options for adaptation. *Agricultural systems*, 54(3), 399-425.
- Raksapatcharawong, M., Veerakachen, W., Homma, K., Maki, M., Oki, K. (2020). Satellite-Based Drought Impact Assessment on Rice Yield in Thailand with SIMRIW- RS. *Remote Sensing*, 12(13), 2099.
- 田中慶, 木浦卓治, 杉村昌彦, 二宮正士, 溝口勝. (2011). SIMRIW を利用した水稻栽

培可能性予測支援ツール．農業情報研究，20(1)，1-12.

以上