

修士論文

近接リモートセンシング技術と深層学習を  
活用した水稻の生育診断

共生環境学専攻

地球環境学講座

フューチャー・アース学研究室

駒田 拓也

519M204

指導教員（主査）：飯島 慈裕 准教授

副査：大野 研 教授

副査：渡邊 晋生 教授

## 要旨

水稻の生育管理を行う上で課題となる要素の一つに緑藻類の存在が考えられる。春先から中干期までの水稻圃場において発生する緑藻類は、移植後の苗に絡みつき稲をなぎ倒したり、水面を被覆して地水温の上昇を妨げたりすることによりその後の水稻の生育に影響を及ぼす可能性がある。本研究では、水稻の植生指標の近接リモートセンシングによる生育環境のモニタリングと深層学習を用いたリモートセンシングデータの解析により、移植後における圃場の水面状態がその後の水稻の生育状況に影響を与えているかを診断することを目的とした。研究対象地は三重県津市の水田圃場である。現地観測として 2019 年の 6 月～8 月にかけて UAV (Unmanned Aerial Vehicle) を用いた近接リモートセンシングによる水稻の生育観測を行い、圃場の可視画像・マルチバンド画像を取得した。その後、取得した画像データをもとに **Structure from Motion** を用いた解析を行い、正射投影画像、正規化植生指標 (NDVI) の画像を合成した。また、深層学習を利用した画像識別手法の一つである **Chopped Picture Method** に基づき、解析した画像データを教師画像に用いて緑藻類の識別モデルを作成した。この識別モデルを正射投影画像に適用することで緑藻の画像識別を行い、2019 年 6 月中の 2 時期における水田圃場内での緑藻の分布を可視化した。さらに、**Chopped Picture Method** による識別結果の正確性を検証するために目視による緑藻判別を行い、2 種類の判別結果を比較することで識別の正確率を算出した。最後に、GIS を用いた解析を行い、圃場内の 6 月の 2 時期における緑藻の密度と 7 月の 4 時期における NDVI の抽出を行い、これら 2 項目間の関係を解析した。解析の結果、モデルによる緑藻識別の正確率は 86%～91.2%であり、十分な精度で圃場内の緑藻を識別することができた。このことから、深層学習より水田内の緑藻を識別することの有効性が示された。また、栄養生長期の緑藻の密度とその後の生殖生長期の NDVI を比較すると、緑藻の密度が低いグループでは NDVI が高く、緑藻の密度が高い区画では NDVI が低下している傾向が見られ、緑藻の分布状況がその後の水稻の生育状態に影響を与えている可能性が示唆された。

キーワード：近接リモートセンシング，深層学習，生育管理，緑藻，NDVI

## 目次

1. はじめに	3
2. 調査対象地と調査手法	
2-1. 調査対象地	5
2-2. 現地観測	5
2-3. Structure from Motion を用いた解析	6
2-4. Chopped Picture Method による解析	7
2-5. 識別結果の正確率の導出	8
2-6. 緑藻の密度と植生指標との比較	9
3. 結果	
3-1. 植生指標	10
3-2. 緑藻類の識別結果	10
3-3. 識別結果の正確率	10
3-4. 緑藻の密度と植生指標との関係	11
4. 考察	12
5. まとめ	14
6. 謝辞	15
参考・引用文献	16
図表	17

## 1. はじめに

### (1) 研究の背景

近年の日本における米の市場価格の変化や、消費者の嗜好の変化に対する稲作農家の方策として、食味の良い高品質・高付加価値な米の生産拡大が行われている。また、稲作の現場では栽培・生育管理を行う担い手の不足が問題となっている。今後少人数の人員で高品質な米を栽培するためには効率的な生育管理・生育診断手法の開発が重要となる。

水稻の品質を向上させる上での課題のひとつとして、移植後の水田圃場表面で発生する緑藻類の存在が挙げられる。緑藻類は生育初期の苗に絡みついて水稻をなぎ倒したり、水面を被覆して地水温の上昇を妨げたりすることにより水稻の生育を遅延させる可能性がある（宮原，1992，p107-108）。したがって、水田移植後の活着期から分けつ期にかけての生育初期段階における水面の緑藻の状態がその後の水稻の生育状況に与える影響を診断する必要がある。

### (2) 先行研究

水稻の生育を広域で調査する手法の 1 つとして、近接リモートセンシング技術が挙げられる、UAV（Unmanned Aerial Vehicle）を用いた近接リモートセンシングを適用することで、圃場内の水稻の生育状態を従来のリモートセンシング（航空写真・衛星画像）よりも高解像度かつ簡便にモニタリングすることができる。また、リモートセンシングで得られる画像情報と深層学習（Deep Learning）による画像認識とを組み合わせることで、水面の藻の発生状況を判別できることが期待される。

稲作に近接リモートセンシングによる観測手法を活用した近年の事例として、濱ら（2016）による「小型 UAV と SfM-MVS を使用した近接画像からの水稻生育モニタリング」の研究や、濱ら（2018）による「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」の研究が挙げられる。前者ではリモートセンシングにより観測された正規化植生指標のデータから草丈、茎数、葉面積指数の推定や推定値を基にした倒伏予測を行っており、後者では植生指標および日射量データから収量予測を行っている。これらの先行研究では、UAV を用いた近接リモートセンシングにより観測された正規化植生指標と、様々な水稻生育環境のデータを組み合わせることで水稻の生育管理に活用できる可能性が示されている。一方で、リモートセンシングで得られる生育状況を、緑藻のよ

うな生育ステージごとに着目すべき成長阻害要因について、その発生状態と関連付けた研究事例はほとんど見られない。

一方で、深層学習により植物の画像認識を行った事例としては、Ise et al (2018) による「Chopped Picture Method (こま切れ画像法)」を用いた苔類の種識別の事例や、Watanabe et al. (2018)による Google Earth の画像から竹林の検出を行った事例が挙げられる。これらの事例で示されている Chopped Picture Method は近年開発された画像識別手法であり、植物の生息域の把握や種の判別等、生態学的分野への活用が期待されている。この手法を緑藻の識別に応用し、水稻の生育管理に生かす方法が開発できれば、農業分野への新しい貢献となると考えられる。

### (3) 研究の目的

以上を踏まえて、本研究では、近接リモートセンシングによる植生指標からの水稻生育状態のモニタリングと深層学習を活用した画像認識によるリモートセンシングデータの解析を複合し、移植後における圃場水面の緑藻類がその後の水稻の生育状況にどのように影響を与えているかを評価することを目的とする。

## 2. 調査対象地と調査手法

### 2-1. 調査対象地

本研究では三重県津市大里睦合町にある「つじ農園」が管理する水田圃場を調査対象地とした。当該地域は志登茂川流域の標高 5～25m にかけての沖積面～低位段丘面に位置し、河川周辺と丘陵地域に水田が広がっている（図 1）。対象圃場ではコシヒカリ、および三重 23 号の品種を栽培している。人口は 887 人、農業就業者数は 27 人である（2015 年国勢調査）。

### 2-2. 現地観測

#### (1) UAV による観測（マルチスペクトル）

調査対象地では 2017～2019 年の水稻生育期間中（6 月～8 月）、雨天の日を避け、週 1 回程度の頻度で UAV による圃場の観測を行った。撮影回数は 2017 年が 6 回、2018 年が 7 回、2019 年が 7 回である。使用した機材はマルチスペクトルカメラ（Sequoia、Parrot 社）を搭載した UAV（SOLO、3DR 社）である。この撮影では可視画像、および緑色領域（530-570nm）、赤色領域（640-680nm）、レッドエッジ（730-740nm）、近赤外領域（770-810nm）のバンドの画像を取得した。撮影は自動操縦によって行い、飛行経路と飛行条件の設定は専用のアプリケーション（Tower : 3D Robotics 社）により設定した。飛行条件は高度 60m、飛行速度 7m/s、サイドラップ率 80%、フロントラップ率 75%とした。この高度での撮影では、画像の空間分解能は約 6cm/px である。

#### (2) UAV による観測（可視画像）

2019 年 6 月 13 日～7 月 16 日の期間で上記の観測とは別に可視画像の撮影を行った。観測頻度は週 1 回で計 6 回撮影した。使用した機材は UAV（Phantom4 : DJI 社）と本体付属のカメラである。こちらも上記の観測時と同様に自動操縦で観測を行い、飛行経路と条件の設定は専用のアプリケーション（Drone Deploy : Drone Deploy 社）によって設定した。撮影条件は高度 30m、オーバーラップ率 80%とした。取得した画像の解像度は約 2cm/px であった。

#### (3) 地上検証および GNSS 測量

2017 年 7 月には UAV を用いたマルチスペクトル観測の地上検証として、可視・近赤外分光放射計（FieldSpec HandHeld2 : Malvern Panalytical 社）を用

いた圃場内の分光反射スペクトルの観測を行った。

また、GNSS 測量機（Reach RTK、Emlid 社）を用いて図 2 に示す圃場周辺の 7 箇所の基準点（GCP: Ground Control Point）を測位した。GNSS 測位については以下に示す手順で行った。

- ①基準点を設定し、各地点に標識板を設置する。
- ②2 種類の測量機（Station と Rover）を準備し、それぞれ、アンテナとバッテリーを接続する。
- ③測位を行う地区周辺で周囲に建造物等の無い開けた場所を探し、Station を設置する。
- ④Rover を持って基準点まで移動し、標識板の中心にアンテナを置く。その後、Rover の電源を入れ、3 分間データを取得する。
- ⑤他の基準点についても、④と同様の工程を繰り返す。
- ⑥測量終了後、取得したデータを RTKLIB（オープンソースソフトウェア）により処理し、基準点の緯度、経度、標高のデータを得る。ここで得られた位置情報は、後述する Structure from Motion を用いた解析に用いた。

### 2-3. Structure from Motion を用いた解析

現地観測にて取得した可視画像、およびマルチバンド画像は Structure from Motion (SfM) を用いて正射変換したオルソ画像（画像上の像の位置のずれを補正し、地図のようにどの地点の地表物も真上から見下ろしたような、正しい大きさと位置に表示した画像）を作成した。SfM は移動するカメラによって撮影された画像から、画像に写った対象物の形状とカメラの動きを復元する手法である。解析には SfM ソフトウェア Metashape ver1.5（Agisoft 社）を使用した。解析手順を図 3 に示す。

解析に使用したデータは調査手法 2-2(1)および 2-2(2)の観測で取得したマルチバンド画像、および可視画像である。画像を元に各種データを生成し、最終的に可視画像および正規化植生指数のオルソモザイク画像を作成した。まず、元画像から画像群の中の特徴点を抽出し、点群データを作成した。次に、生成された点群データから不要な箇所を除外した後、調査手法 2-2(2)の GNSS 測位にて得られた圃場周辺の位置情報を付加し、データの補正を行った。その後、点群データを高密度化する操作を行い、高密度の点群データから、樹木や建造物等の高さを含めた地表面の標高モデルである数値表層モデル（DSM: Digital Surface

Model) を生成した。最後に、DSM をもとにオルソモザイク画像の作成を行った。マルチバンド画像を元データとした解析の場合はここでラスター演算の機能を用いて、赤色領域と近赤外領域のラスターから正規化植生指標 (NDVI: Normalized Difference Vegetation Index) を計算し、植生指標の分布画像を作成した。植生指標の計算には以下の式を用いた。

$$\text{NDVI} = \frac{\text{NIR} - \text{RED}}{\text{NIR} + \text{RED}}$$

$$-1 \leq \text{NDVI} \leq 1$$

ここで、NIR、RED はそれぞれ近赤外領域、赤色領域における分光反射率を表す。

## 2-4. Chopped Picture Method による解析

### (1) 手法の特徴と解析の手順

「Chopped Picture Method (こま切れ画像法)」は Ise et al. (2018) によって開発された深層学習 (Deep Learning) を用いた画像識別手法のひとつである。この手法の特徴として、①一枚の大きな画像をこま切れに (数十ピクセル四方の小さな画像に細分化) したものを教師画像として学習を行うこと、②画像中の植物の種を識別することが可能であること、が挙げられる。従来の深層学習を使用した画像認識手法では、植物の持つ可塑性 (周囲の環境に応じて、植物体が多様な形状に生長していく) や自己相似性 (植物全体を見た場合と、植物の一部分を見た場合の形状が似ている) といった特性から、植物体を識別することは難しいとされている (Ise et al., 2018)。一方でこま切れ画像法では、対象物の輪郭の特徴を学習するのではなく、対象物表面のテクスチャ (模様) の特徴を学習するため、植物を識別することが可能である。

この解析では、画像の細分化や判別結果の可視化といった画像処理に統計解析ソフト R、および専用の R スクリプトを用い、対象物を識別する際の深層学習には深層学習システム Digits6 (Nvidia 社) を使用した。Digits6 によるトレーニングでは畳み込みニューラルネットワークによる深層学習を行っている。

解析手順を図 4 に示す。まず、識別対象となる地表物 (今回の解析では緑藻類) と対象外の地表物 (道路、雑草、稲株等) が写った 2 種類の元画像を用意し



た（図 4 ①）。次に用意した画像を R スクリプトを用いて数十ピクセル四方の細かい画像に分割した（図 4 ②）。その後 Digits6 側に画像のデータセットを転送し、教師画像に基づいてトレーニングを行うことで識別モデルを作成した（図 4 ③）。モデル作成の際、データセットのうち、3/4 が識別モデル作成の為に教師画像として使用され、残りの 1/4 の画像はモデル判別精度の検証結果を出力するために使用された（図 4 ④）。モデルを作成した後は、任意の画像（対象物の検出を行いたい画像）を教師画像の時と同様に細分化し、判別モデルに適応することで、判別結果を出力した（図 4 ⑤）。最後に、得られた判別結果を、R スクリプトを用いて可視化した（図 4 ⑥）。

## (2) 使用したデータ

今回の解析には、調査手法 2-2(2)の観測で得られた可視画像を基に 2-3 の解析で作成したオルソモザイク画像を用いた。オルソモザイク画像は 6 月～7 月までの撮影分が存在したが、7 月以降のデータでは稲株が生長し、葉が圃場表面を覆って緑藻類や水面の判別が難しい状態であったため解析対象から除外した。また、6 月に撮影した画像のうち 6 月 13 日分については、水面に太陽光の反射が強く映りこんでおり、緑藻の検出には不適と判断したためこちらも除外した。なお、調査手法 2-2 (1) の観測では、2017 年、2018 年の可視画像データも取得していたが、撮影高度の設定が 60m と 2-2 (2) の観測よりも高く、それに従って画像の分解能も低いことから、これらの画像に関しても緑藻類を判別するには解像度が不十分であると判断した。よって、解析には 6 月 20 日、6 月 27 日の 2 時期のオルソモザイク画像を使用した。教師画像は 6 月 20 日のオルソモザイク画像の内、図 5 に示した南西の圃場部分から取得した。緑藻類の識別を行う圃場は北側の 2 圃場（西圃場、東圃場）に定め、それぞれの圃場で 6 月 20 日と 6 月 27 日の両時期の緑藻の分布を識別した。

## 2-5. 識別結果の正確率の導出

調査手法 2-4 で得られた緑藻類の判別結果がどの程度の正確性を持っているかを検証するために、ArcMap（Esri 社）を用いて解析を行った。その解析手順を以下に示す。

まず、可視化した判別結果の画像を ArcMap に取り込み、ジオリファレンスの操作を行い画像に位置情報を付加することで、識別前のオルソモザイク画像

との位置合わせを行った。次に、判別結果の画像から、緑藻類が存在する地点のピクセル値を 1、存在しない地点のピクセル値を 0 としたラスターを作成した。その後、図 6 に示すように西圃場の範囲内に 200 地点、東圃場の範囲内に 250 地点のポイント作成し、各地点のピクセル値をサンプリングした。同時に、設定した地点における緑藻類の有無を目視により判別を行い、サンプリングしたピクセル値（2-4 で得られた緑藻類の識別結果）との比較を行った。正確率については、以下の式で算出した。

$$(\text{識別の正確率}) = (\text{識別結果が一致した地点数}) / (\text{全地点数})$$

## 2-6. 緑藻類の密度と植生指標との比較

緑藻類の分布がその後の水稻の生育状態に影響を与えているかを評価するために、ArcMap 上で緑藻類の密度を算出し、植生指標との相関関係について調べた。図 7 に示すように圃場を 5m×5m の小さな区画に分割したポリゴンを作成した。次に調査手法 2-5 において作成した、緑藻ありの地点のピクセル値を 1、なしの地点のピクセル値を 0 としたラスターから区画ごとにピクセル値をサンプリングし、平均値（区画内の緑藻ありピクセル数／区画内のピクセル値合計）を算出した。このピクセル値の平均値をその区画における緑藻の密度とし、西圃場、東圃場のそれぞれについて 6 月 20 日、6 月 27 日時点での緑藻の密度を算出した。また、植生指標については、調査手法 2-2(1)および 2-3 で作成した植生指標画像の内、2019 年 7 月 10 日～8 月 29 日の間の 7 時期のものを対象とし、同じ区画ごとに NDVI の平均値を算出した。対応する区画について算出した緑藻の密度と NDVI の平均値との散布図を作成し、2 項目間の相関を調べた。

### 3. 結果

#### 3-1. 植生指標

NDVI のオルソモザイク画像を図 8 から図 14 に示す。それぞれ 2019 年 7 月 10 日から 2019 年 8 月 29 日の期間中の 7 時期の NDVI である。

西圃場、東圃場に注目して NDVI の時系列変化を見ると、7 月中の出穂期までの時期では、両圃場とも圃場の北側で NDVI が高く、南側で低い傾向が見られた。出穂が進み 8 月に入ると圃場内に見られた NDVI の不均一性が小さくなっていることがわかる。その後、8 月後半で NDVI 値が全体的に落ち込み始め、収穫前の時期である 8 月 29 日には NDVI 値が低くなっている。

#### 3-2. 緑藻の識別結果

こま切れ画像法により緑藻を識別した結果を図 15 から図 18 に示す。図 15、図 16 は西圃場における 6 月 20 日、6 月 27 日時点での識別結果を、図 17、図 18 は東圃場における 2 時期の判別結果を表す。

東圃場は西圃場と比較して、2 時期ともに圃場全体に対する緑藻の面積が小さいことが確認できる。また、西圃場において 6 月 20 日時点では圃場南西から東の中央部付近にかけて大きな緑藻のかたまりが見られ、北部分では小さなかたまりが確認できるのに対し（図 15）、6 月 27 日時点では圃場南東で大きな緑藻のかたまりが新たに発生しており、北側で分布域が増加していることが分かる（図 16）。東圃場では、6 月 20 日時点で確認された圃場北東、南東部分の分布（図 17）が 6 月 27 日時点では消えており、新たに北西部と南西部に分布していることが確認できる（図 18）。

#### 3-3. 識別結果の正確率

調査手法 2-5 において導出した緑藻の識別結果の正確率を表 1 に示す。表で用いられている偽陰性、偽陽性の結果については、ここでは「目視による判別結果（検証用データ）では緑藻ありであったが、こま切れ画像法の結果では緑藻なし」であった場合を偽陰性、「目視の判別では緑藻なしであったが、こま切れ画像法の結果では緑藻あり」の場合を偽陽性としている。

各識別結果の正確率は、西圃場では 6 月 20 日が 90.5%、6 月 27 日が 87%、東圃場では 6 月 20 日が 91.2%、6 月 27 日が 86% となった。西圃場、東圃場とも 6 月 20 日と比較して、6 月 27 日の正確率は低くなっている。また、すべて

の検証結果において、地点数に対する偽陰性数の割合は偽陽性数の割合よりも高い結果となった。

### 3-4. 緑藻の密度と植生指標との関係

調査手法 2-6 に基づく 6 月時点の緑藻の密度と 7 月以降の NDVI との関係を図 19 から図 22 に示す。ここでは西圃場、東圃場それぞれについて、栄養生長期における 2 時期 (6/20, 6/27) の緑藻の密度とその後の生殖生長期における 4 時期 (7/10, 7/16, 7/24, 7/31) の NDVI との比較を行った。図中の色の異なる点は、6 月 20 日から 6 月 27 日にかけての緑藻密度の変化幅に応じて、減少 (密度が 0.05 以上減少)、変化なし (変化幅が -0.05 ~ 0.05 の範囲内)、増加小 (0.05 ~ 0.3 増加)、増加大 (0.3 以上増加) のグループに分けた各区画を示している。

西圃場において、6 月 20 日から 6 月 27 日で緑藻密度が変化したことによる散布図内のグループの動き (図 19a → 図 20a) を見ると、緑藻の密度が増加大グループ < 変化なし < 増加小 < 減少の順で高かったものが (図 19a)、変化なし < 減少 < 増加小 < 増加大の順で密度が高い分布へと変化していることが分かる (図 20a)。この変化は NDVI の時期を変化させても同様の動きが確認できた (図 19b, c, d → 図 20b, c, d)。一方、東圃場での変化を見ると (図 21a → 図 22a)、緑藻密度が増加小・増加大 < 変化なし < 減少の順で高かったもの (図 21a) が、減少・変化なし < 増加小 < 増加大へと変化している (図 22a) ことが確認できる。NDVI が変化しても同様の動きが見られた (図 21b, c, d → 図 22b, c, d)。

## 4. 考察

### (1) モデルの識別精度について

表 1 において、6 月 27 日の識別結果は 6 月 20 日と比較して正確率が低い傾向が確認された。要因の一つとして、2 時期の水稻生育ステージの差が挙げられる。水稻の分けつや葉の成長に伴って、上空から見た場合の水稻が水面を被覆したため、モデルによる識別に影響を与えた可能性が考えられる。特に移植時期が早く、水稻の生育が進んでいた東圃場 6 月 27 日の結果（図 18）では、圃場北西部で緑藻が誤って検出されている箇所が固まって分布している様子が、目視による判別との比較から確認された。

Watanabe et al. (2018)による、Google Earth 画像を用いて Chopped Picture Method を適用し竹林の識別を行った研究事例では、ある地域の画像を教師データとして作成したモデルを用いて他の地域の竹林を認識させた場合、同じ地域の竹林を認識する場合と比較して認識精度が低下したという結果が報告されており、画像が撮影された際の気象等の撮影条件の違いがモデルの識別精度に影響を与えていることが指摘されている。したがって、今回行った解析はすべて同一の地域ではあるものの、撮影日の雲量等の条件の違いから画像の色味に差が生じることで、識別の正確性に影響を与えた可能性ももう一つの要因として考えられる。

今回作成した識別モデルにより、全体として 90%前後の正確率で圃場内の緑藻を識別することができた。先行研究におけるモデルの識別精度を見ると、Ise et al. (2018)の事例では 90%以上の精度があり、Watanabe et al. (2018)の事例においても識別結果が良好なモデルではおよそ 90%以上の正確率で対象物を識別している。これらの結果と比較しても、今回のモデルは十分な精度で緑藻を識別できたと考えられる。

### (2) 緑藻の密度と NDVI との関係について

図 19、図 20 の西圃場での関係に注目すると、2 時期で緑藻密度に変化の無かったグループでは緑藻の密度が低い地点が多く、集団全体を見た場合、他のグループと比較して NDVI 値が高い傾向が見られた。密度が大きく増加（0.3 以上）したグループは、6 月 20 日時点では密度が低く、6 月 27 日で最も密度の高い集団となっており、NDVI 値は他グループと比べると低い傾向が確認できる。密度が減少したグループは、前述した 2 グループと比較すると緑藻密度

の幅が大きい集団であるが、密度減少前の 6 月 20 日（図 19）では、密度の高い区域では NDVI 値が低く、密度の低い区域で NDVI 値が低い傾向が見られる。増加小（0.05~0.3 増加）のグループは減少グループと同様に密度の幅が広い集団で、6 月 27 日（図 20）では密度が低い区域で NDVI 値が高く、密度が高い区域で NDVI が低い傾向が確認できる。なお、東圃場（図 21, 図 22）ではこれらの傾向は確認できないが、上述した図 18 の結果における誤識別による影響が考えられる。

以上より、西圃場においては、全体で見ると緑藻の密度と NDVI の間に直線的な相関はないものの、いくつかのグループに分けて見ると、密度が低く NDVI 値が高い集団と密度が高く NDVI 値が低い集団に分かれて分布しており、緑藻の密度がその後の NDVI 値に影響を与えている可能性が示唆されている。

また、緑藻の密度が高い区画（0.3 以上）と低い区画（0.3 未満）ごとに NDVI 値の頻度を示すと（図 23, 図 24）、2 集団の間で分布の仕方が異なっており、密度が低い区画（図 23a, 図 24a）では高い区画（図 23b, 図 24b）と比較してピークとなる NDVI 値が高いことが確認できる。このことから、緑藻の分布している箇所では水稻の生育が落ち込む傾向が示唆された。

### (3) 農家の経験知との比較

調査対象地の水田を管理している農家の私信では、冬季に圃場の土づくりとして有機物（米ぬか）散布を行った圃場では緑藻が発生していることが指摘されている。また、解析対象とした圃場のうち、西圃場では圃場の北側、および南西側に藻が多く発生していたと述べられている。3-2 において示した識別結果にも、圃場の北部分（図 16）や南西部分（図 15, 図 16）に密集して分布している様子が認められ、深層学習させたモデルによる識別結果が、農家の持つ経験知の科学的な裏付けとなっている可能性が示唆された。

このことから、リモートセンシングと深層学習による緑藻の検出を他の生育管理情報と組み合わせることにより、農家が圃場の土づくりを行う際に有機物の散布量や散布方法を調整することで事前に緑藻の発生を抑制する、といった生育管理手法の改善への活用が期待できる。

## 5. まとめ

本研究では UAV を使用した近接リモートセンシングによる植生指標の観測、「Chopped Picture Method」を用いた画像識別モデルの作成、栄養生長期における水田圃場の緑藻類の識別を行い、識別結果から導出された緑藻の密度と生殖生長期における NDVI との関係について調査した。モデルにより 2 時期の 2 つの圃場で識別を行った結果、教師画像と同じ生育ステージでは目視による判別と比較して両圃場で 90%以上の精度で緑藻を識別することができた。また、教師画像から 1 週間程度生育が進んだ状態では識別精度はやや低下したものの、85%以上の精度が得られた。このことから、深層学習を活用して水田圃場内の緑藻を識別することの有効性が示された。

また、緑藻密度と NDVI との比較結果からは、緑藻密度の高い集団では NDVI が低く、緑藻密度の低い集団では NDVI が高くなる傾向が確認され、栄養生長期の緑藻の密度が、その後の生殖生長期における水稻の生育状態に影響を与えている可能性が示唆された。

これらの結果は、水稻栽培の現場において近接リモートセンシング技術による圃場観測を行い、そこから得られたデータを深層学習によりさらに解析することで、生育管理に役立つ情報を得られる可能性を示している。栽培品目の高付加価値化や担い手の不足が進むと予想される将来の日本の稲作現場において、これらの技術を効率的な生育管理に生かしていくことが期待される。

本研究の今後の課題としては、圃場内の他の生育環境データとの関連付けを行うことで、緑藻が水稻の生育に与える影響をより詳細に解明することが考えられる。今回の研究では、緑藻の密度と植生指標との関係について、リモートセンシングにより得られた情報のみから定性的な評価を行うに止まった。そのため、植生指標データの取得と深層学習による緑藻の識別に、緑藻発生前の圃場の土壌養分や緑藻・水稻の窒素利用等の分析を加えて植物生理と関連付けた研究に発展させていくことが考えられる。

## 6. 謝辞

本研究を行うにあたり、ご指導いただきました飯島慈裕准教授に厚く感謝申し上げます。また、調査・解析を進める上でご助力いただきましたつじ農園の辻武史氏、土壌圏システム学研究室の渡邊晋生教授、佐藤のぞみ氏、京都大学フィールド科学教育研究センターの伊勢武史准教授に深い感謝の意を表します。



## 参考・引用文献

- (1) 竹内渉, 安岡善文 : 衛星リモートセンシングデータを用いた正規化植生, 土壌, 水指数の開発, 写真測量とリモートセンシング, 43(6), pp.7-19, 2004
- (2) 濱侃, 早崎有香, 望月篤, 鶴岡康夫, 田中圭, 近藤昭彦 : 小型 UAV と SfM-MVS を使用した近接画像からの水稻生育モニタリング, 水文・水資源学会誌, 29(1), pp.44-54, 2016
- (3) 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 : 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), pp.68-82, 2018
- (4) 坂本利弘, 岩崎亘典, 石塚直樹, David S. Sprague : 小型 GNSS 受信機および測位演算プログラムパッケージ「RTKLIB」による対空標識の簡易・高精度測位手法に関する事例研究, 日本リモートセンシング学会誌, 39(2), pp.123-132, 2019
- (5) Takeshi Ise, Mari Minagawa, Masanori Onishi : Identifying 3 moss species by deep learning, using the "chopped picture" method, Open Journal of Ecology 08(03), 2018, doi: <https://doi.org/10.4236/oje.2018.83011>
- (6) Shuntato Watanabe, Kazuaki Sumi, Takeshi Ise : Using deep learning for bamboo forest detection from Google Earth images, 2018, doi: <https://doi.org/10.1101/351643>
- (7) 山岸淳, 橋爪厚 : 水田の緑藻類の生態と防除に関する 2, 3 の知見, 雑草研究, 18, pp.39-43, 1974
- (8) 宮原益次, 水田雑草の生態とその防除 : 水稻作の雑草と除草剤解説, 全国農村教育協会, 1992
- (9) 藤田裕子, 中原紘之 : 水田の田面水と土壌における藻類群集の季節変化, 陸水学雑誌, 60(1), pp.67-76, 1999

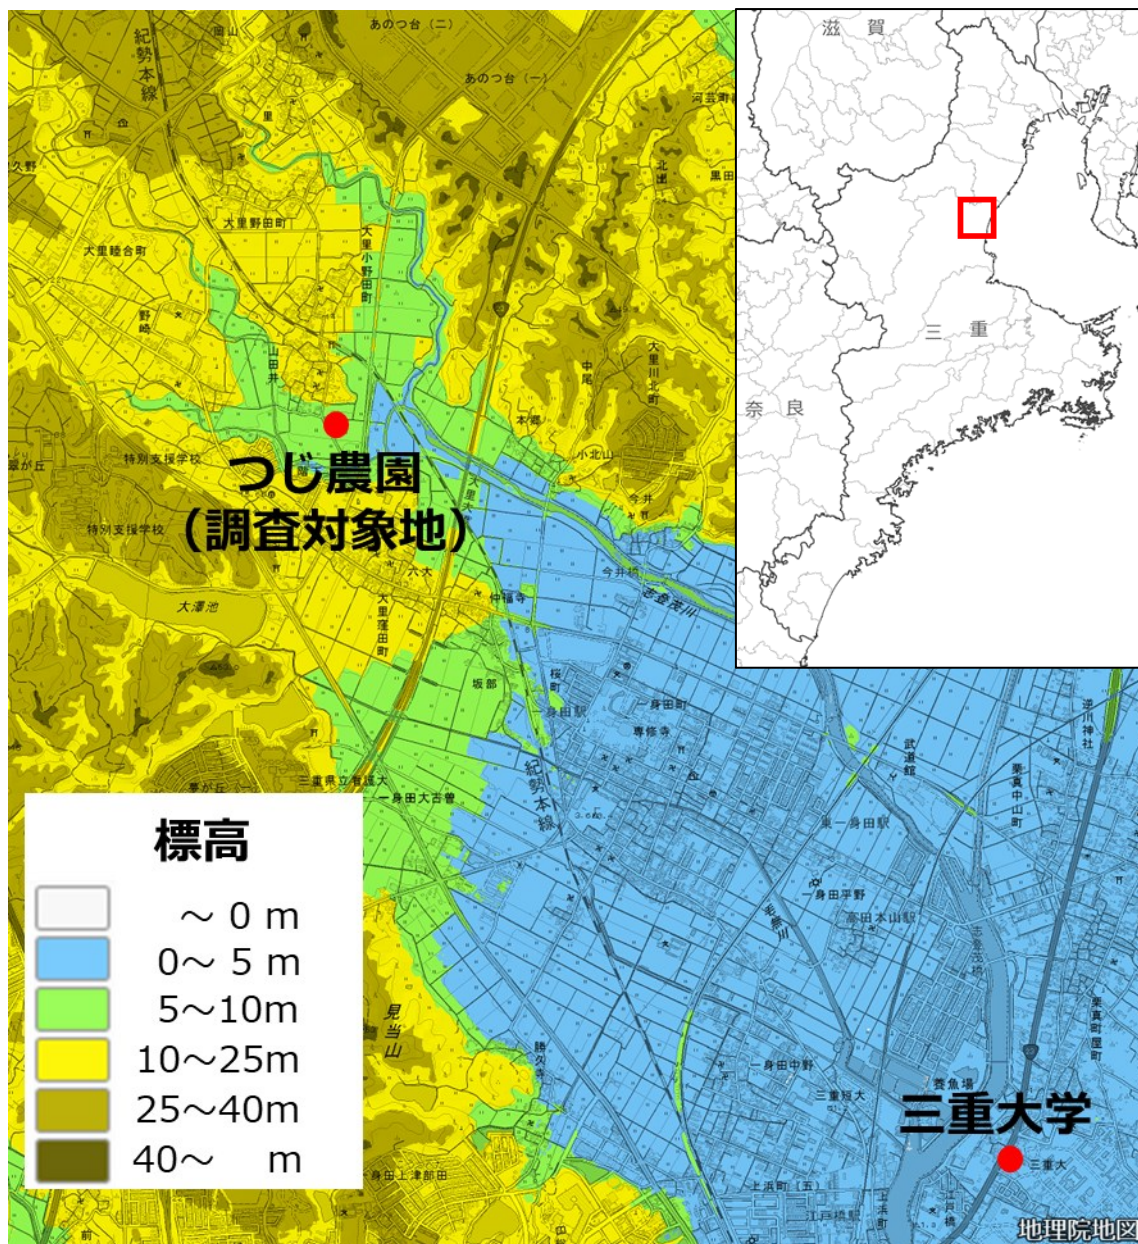


図 1. 調査対象地（地理院地図より作成）




図 2. 圃場周辺の基準点

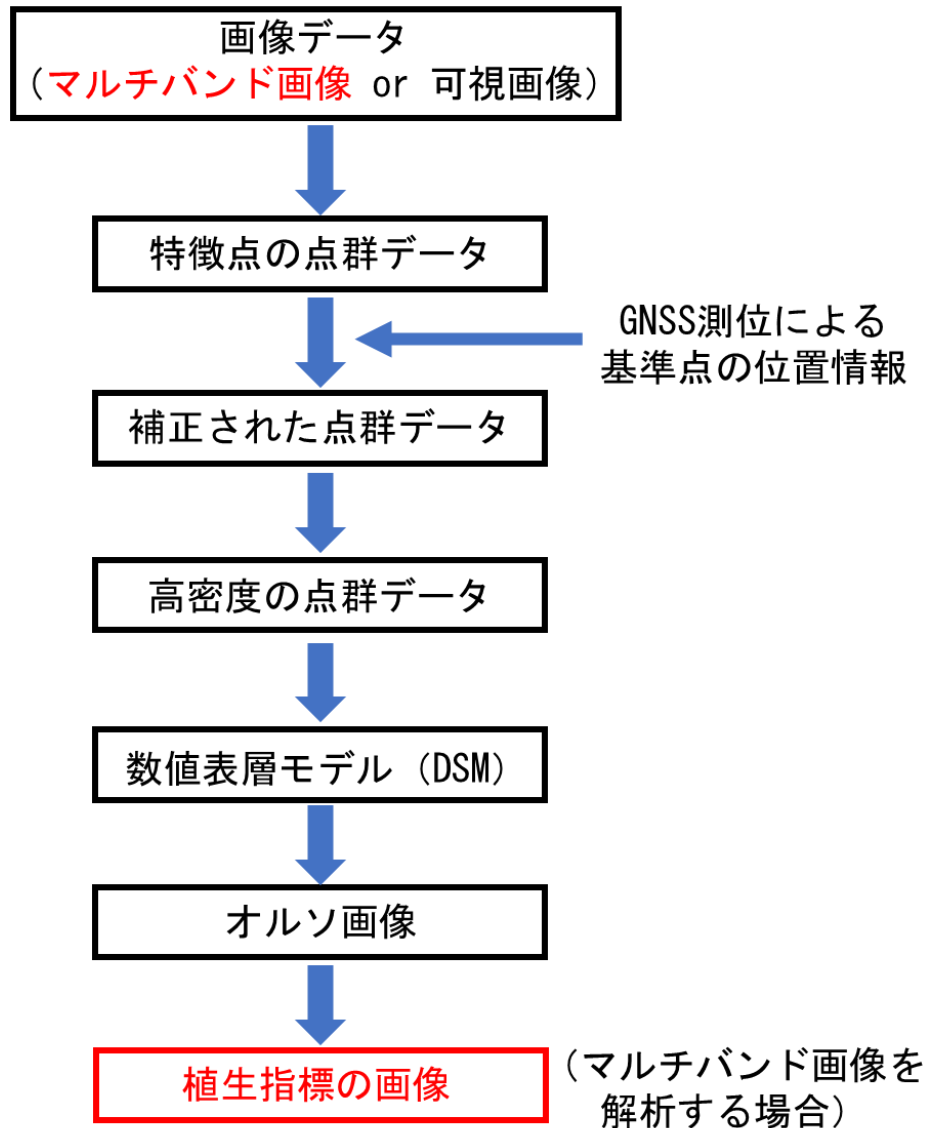


図 3. Structure from Motion による解析手順  
(Metashape ver1.5 を使用)



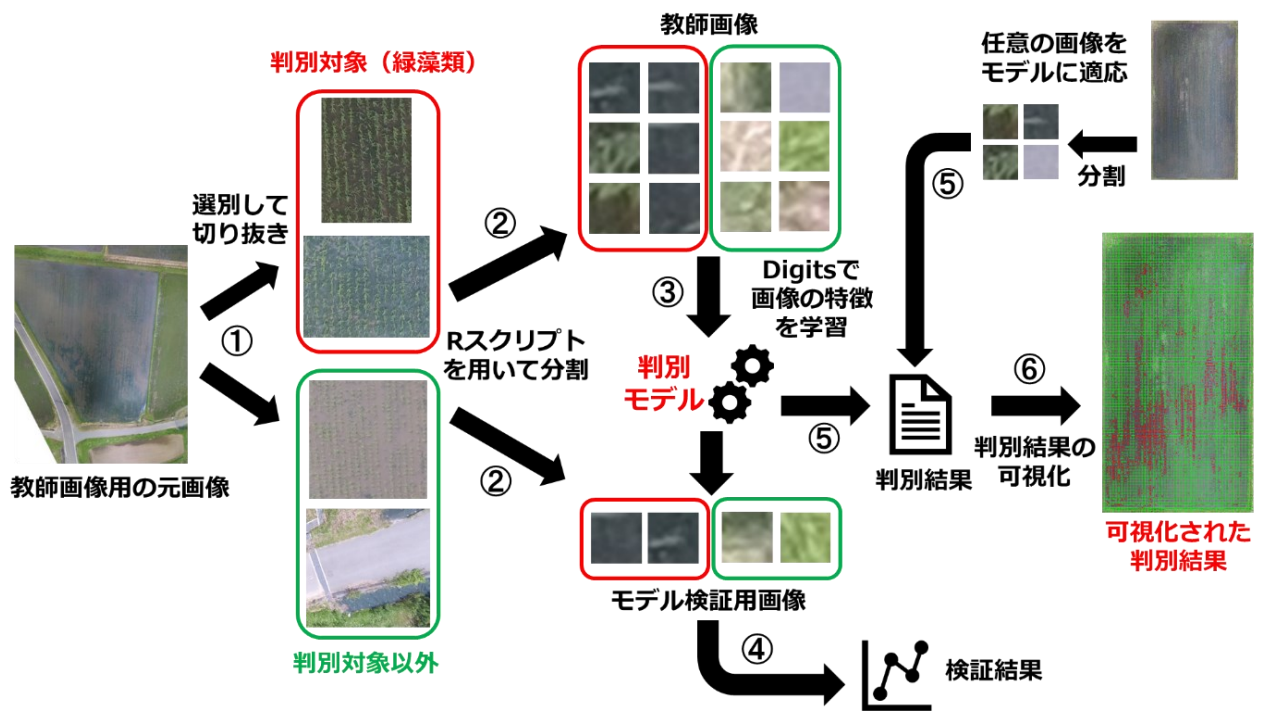


図 4. Chopped Picture Method による解析手順



図 5. 識別対象圃場と教師画像の圃場




図 6. 識別結果の比較地点（西圃場：200 地点、東圃場：250 地点）






図 7. 格子状の区画  
(西圃場を  $8 \times 15$  の区画、東圃場を  $10 \times 15$  の区画に分割した。  
一区画の大きさは  $5\text{m} \times 5\text{m}$ )






図 8. 圃場内の NDVI (2019 年 7 月 10 日)




図 9. 圃場内の NDVI (2019 年 7 月 16 日)




図 10. 圃場内の NDVI (2019 年 7 月 24 日)






図 11. 圃場内の NDVI (2019 年 7 月 31 日)




図 12. 圃場内の NDVI (2019 年 8 月 7 日)




図 13. 圃場内の NDVI (2019 年 8 月 18 日)






図 14. 圃場内の NDVI (2019 年 8 月 29 日)




図 15. 緑藻の識別結果（2019 年 6 月 20 日、西圃場）






図 16. 緑藻の識別結果（2019 年 6 月 27 日、西圃場）






図 17. 緑藻の識別結果（2019 年 6 月 20 日、東圃場）





図 18. 緑藻の識別結果（2019 年 6 月 27 日、東圃場）

表 1. Chopped Picture Method による緑藻識別の正確率


	西圃場 6/20	西圃場 6/27	東圃場 6/20	東圃場 6/27
地点数	200	200	250	250
一致数	181	174	228	215
偽陰性数	17	20	18	25
偽陽性数	2	6	3	10
正確率	90.5%	87%	91.2%	86%

※偽陰性：目視による判別結果では緑藻あり、モデルの識別結果では緑藻なし  
 偽陽性：目視による判別結果では緑藻なし、モデルの識別結果では緑藻あり







(a) NVDI 値 : 7 月 10 日



(b) NVDI 値 : 7 月 16 日




(c) NVDI 値 : 7 月 24 日




(d) NVDI 値 : 7 月 31 日

▲減少 ●変化なし ◆増加小 ■増加大


図 19. 緑藻の密度と NDVI 値との関係 (西圃場)  
(緑藻の密度 : 6 月 20 日時点のデータ)




(a) NVDI 値 : 7 月 10 日



(b) NVDI 値 : 7 月 16 日




(c) NVDI 値 : 7 月 24 日




(d) NVDI 値 : 7 月 31 日

▲減少 ●変化なし ◆増加小 ■増加大


図 20. 緑藻の密度と NDVI 値との関係 (西圃場)  
(緑藻の密度 : 6 月 27 日時点のデータ)




(a) NVDI 値 : 7 月 10 日



(b) NVDI 値 : 7 月 16 日




(c) NVDI 値 : 7 月 24 日




(d) NVDI 値 : 7 月 31 日

▲減少 ●変化なし ◆増加小 ■増加大


図 21. 緑藻の密度と NDVI 値との関係 (東圃場)  
(緑藻の密度 : 6 月 20 日時点のデータ)




(a) NVDI 値 : 7 月 10 日



(b) NVDI 値 : 7 月 16 日



(c) NVDI 値 : 7 月 24 日




(d) NVDI 値 : 7 月 31 日


▲減少 ●変化なし ◆増加小 ■増加大

図 22. 緑藻の密度と NDVI 値との関係 (東圃場)  
(緑藻の密度 : 6 月 27 日時点のデータ)






(a) 緑藻密度 0.3 未満 (6/20)




(b) 緑藻密度 0.3 以上 (6/20)

図 23. 緑藻密度の低い区画 (0.3 未満) と高い区画 (0.3 以上) における NDVI の頻度分布  
(緑藻密度 : 6 月 20 日、NDVI : 7 月 16 日)



(a) 緑藻密度 0.3 未満 (6/27)



(b) 緑藻密度 0.3 以上 (6/27)

図 24. 緑藻密度の低い区画 (0.3 未満) と高い区画 (0.3 以上)  
 における NDVI の頻度分布  
 (緑藻密度 : 6 月 27 日、NDVI : 7 月 16 日)