

植物のスペクトル反射特性を用いた RGB画像からの近赤外画像の推定

三島 駿祐^{1,a)} 金澤 靖^{1,b)}

概要 :

画像処理の農業への応用において、近赤外線画像や Red Edge 画像は、NDVI や NDRE などの植生指標を計算するために使われ、作物の活性度をセンシングするために重要な情報となっている。しかし、その撮影においては高価なマルチスペクトルカメラとその撮影手段が必要となる。一般には人工衛星や航空機に積まれたマルチスペクトルカメラを用いるが、撮影時間やその解像度を指定する困難である。そこで本研究では、比較的安価なドローンに搭載されている、通常の可視チャンネルのカメラによる画像から近赤外画像や Red Edge 画像を推定することを考える。これにより、安価なドローンで撮影した映像から、いつでも好きなときに圃場の状況を確認することが可能となる。本稿では、深層学習による手法と多層パーセプトロンによる回帰による手法の2つの手法を提案する。実際の柿圃場の画像により、提案法の有効性を示す。

Estimation of NIR Image from RGB Image using Spectrum Characteristic of Vegetable

Abstract:

We propose an estimation method of infrared image from visible image. In agriculture, near infrared images and red edge images are usually used for estimating a condition of field like NDVI and NDRE. These images are generally taken by multi spectral camera. Farmers cannot use the multi spectral camera easily because of its cost. In this paper, we consider to estimate near infrared image and red edge image from normal RGB image. For doing this, we propose two methods: deep learning based and regression based. By using our method, it becomes possible to use infrared images without using a multispectral camera. We show the effectiveness of our methods by experiments with the real images taken from a persimmon field.

1. はじめに

近赤外画像や Red Edge 画像を用いた多くの画像解析技術は、工場の異物検査や航空機からの鉱脈調査だけでなく、ドローンなどの UAV 技術の発展に伴い、農業分野への応用も始まっている。例えば、作物の収穫時期の推定や、土壌や植物の活性度の調査などに使われており、従来は衛星画像や航空機画像を用いたりリモートセンシング [1], [2], [3] が主であったが、近年はドローン等の UAV 機器に取り付けたカメラから取得した画像を用いるもの [4], [5], [6] も多い。衛星画像や航空機画像に比べ、ドローン映像の農業応用は、その手軽さもあり、さらなる技術発展への期待も高

まっている。

このように様々な機材を用いて農業の管理を行うことを精密農業 [7] といい、農家にとって大変な労力を要する作業である田畑の見回りの負担を軽減させることができるとして期待が高まっている。精密農業の流れは以下のようになっている。

- 農地や農作物の状況をよく観察する。
- その状況に応じてきめ細かく制御する。
- その成果に基づいて次年度の計画を立てる。

この精密農業は、農作物の収量や品質の向上を目的としており、これを行うためには、観察、制御、収穫、解析のツールが必要となる。この中で最も重要な位置を占めるのが農作物の生育状況を把握するための観察ツールである。従来の観察ツールは前述のように衛星画像を用いたりリモートセンシングにより行われているが、これは一般に高高度から

¹ 豊橋技術科学大学 情報・知能工学系
Toyohashi University of Technology

a) mishima@img.cs.tut.ac.jp

b) kanazawa@cs.tut.ac.jp

の撮影データを使用するため、複数の圃場を跨ぐような地区全体の生育状況の把握には適しているが、一つ一つの圃場や、作物一つ一つの状況把握にはあまり適していない。また、観測頻度も限られているため、稲などの比較的長時間に渡る作物の状況把握には有効であるが、露地野菜などの短期間で栽培される作物にはあまり有効ではない。

そこで近年、精密農業の分野では、ドローンに取り付けたカメラを用いて定期的に撮影を行い、画像解析の手法を用いて撮影画像を解析している [8]。ドローンはその制御の高性能化により、誰でも容易に操縦することができ、設定によっては計画的な自律飛行も可能になっている。また、可視カメラの他にもマルチスペクトルカメラやレーザーレンジファインダを搭載することも可能であり、それらを用いることで様々な情報のセンシングが可能である。さらには、農薬散布や物の配布が可能なものも存在する。しかし、このような多機能、高機能なドローンは高価であり、個々の農家では導入することが難しい。

そこで本論文では、一般の RGB カメラで撮影された RGB 画像より近赤外画像や RedEdge 画像を推定し、そこから植生指標を計算する手法を提案する。本論文では、柿の葉に固有のスペクトル反射特性を用いて多層パーセプトロンによる重回帰分析によって推定を行う方法と、pix2pix を用いて直接 NIR 画像及び Red Edge 画像の推定を行う方法の 2 つを提案し、それらの手法の比較を行う。

2. 植生指標

植生指標とは、画像内の植生の健康度、活性度を調査するための指標であり、NDVI (Normalized Difference Vegetation Index) が一般的である。NDVI は $[-1, 1]$ の範囲で表され、数値が大きい程植生が活発であることを示す。また NDRE (Normalized Difference Red Edge) は、NDVI において Red チャンネルの代わりに Red Edge チャンネルの値を用いることで計算することができる指標であり、一般に葉の重なりが多い植物の解析に利用される。ここで、Red Edge チャンネルとは、NIR と可視光帯の間に存在する波長であり、植生においてはこの波長で反射率が急激に変化する。Red Edge の反射の測定は、植生の栄養状態と葉面積指数の評価に利用可能であり、更に、植生のストレスの早期検出にも適していることが分かっている [9]。

各植生指標は以下のように計算される。

$$\text{NDVI} = \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}} \quad (1)$$

$$\text{NDRE} = \frac{\text{NIR} - \text{RedEdge}}{\text{NIR} + \text{RedEdge}} \quad (2)$$

ここで、NIR は NIR チャンネルの画素値、Red は R チャンネルの画素値、RedEdge は Red Edge 画像の画素値を表す。

この植生指標を用いた研究として、多田ら [3] は、広葉




図 1 決定木の生成に用いた画像 (左: 原画像, 右: セグメンテーション後の画像)。

樹林帯の蒸発散分布の推定に NDVI を用いている。ここでは、衛星画像より計算した NDVI と広葉樹林帯における蒸発散分布を重回帰分析によって定式化している。植生指標を用いると、単に植生の活性度を知ることが出来るだけでなく、植生の外部への作用も調査することができる。

田中ら [6] は、小型マルチコプターを用いて近接リモートセンシングを行い、植生指標を計算することで水稻の生育度を示すマップの作成を行っている。ここでは、衛星画像を用いた大域的な調査ではなく、天候の影響を受けにくい低空を高頻度で撮影することで、個人でも運用可能なシステムを提案している。

また Red Edge バンドは、植物の活性度だけでなく、病害の早期発見 [10] や森林タイプの分類 [11] にも使われている。

このように、圃場における活性化状況等を把握するためには、可視画像だけでなく、近赤外画像や Red Edge 画像が必要となるが、近赤外画像や Red Edge 画像を撮影できるカメラは高価であり、農家の規模によっては容易に導入することはできない。

3. 提案法

本研究では、通常の RGB 画像から近赤外画像や Red Edge 画像を推定することで、通常のカメラを搭載したドローンのみで、各種植生指標を求め、植物の活性化具合の評価を行なえるようにする。

ここでは、可視スペクトル情報から近赤外および Red Edge スペクトル情報を回帰によって求める方法と、DCGAN[12] の一つである pix2pix[13] を用いた可視画像からの近赤外および Red Edge 画像の推定を行うことを考える。

以下に、それぞれについて簡単に説明する。

3.1 回帰による推定

回帰による推定を行なうには、まず回帰に適さない情報を除去することが必要となる。そこで、まず土地の被覆分類を行ない、そこから植生とそれ以外に分類して、植生と判断された部分から回帰を行なう。

3.1.1 土地被覆分類

衛星画像を用いた土地被覆分類は、土地利用図や植生図の最新の情報としての利用がされている。その他にも、土砂災害などの危険区域の分類などにも用いられる。




図 2 各物体のスペクトル反射特性

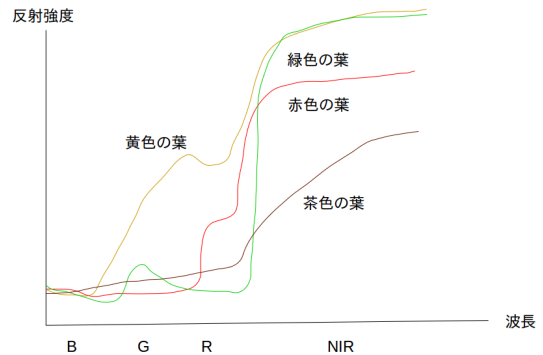


図 3 植物のスペクトル反射特性

土地被覆分類は、地表の物体のスペクトル反射特性が異なることを利用して土地の分類を行うものである。分類は、教師付き分類によって行われるのが一般的である。衛星によって撮影されたマルチバンドの画像の情報から、レベルスライス法や最尤法などを用いて市街地、森林などあらかじめ設定しておいたカテゴリに分類する。現在、アメリカ航空宇宙局が打ち上げている人工衛星の Landsat が撮影したデータがウェブ上に公開されており、それを用いて各種解析を行うことができる [15]。

本論文では、この土地被覆分類を NIR 画像及び Red Edge 画像の推定に用いるため、ドローンに搭載したマルチスペクトルカメラより取得したデータによって行う。

画像内の全ピクセルを同一の回帰モデルで近似することは、物体毎のスペクトル反射特性が異なることを考えると困難である。そこで、画像内のピクセルを複数のカテゴリに分類し、カテゴリごとに別の回帰モデルを用いて近似することを考える。説明変数として RGB, IR, Red Edge を用い、決定木を用いて植生とその他の 2 カテゴリに分類を行う。学習データとして、RGB 画像と手作業でセグメンテーションを行った画像 2 組を用いる (図 1)。

この方法で学習した決定木を用いて土地被覆分類を行うと、入力として NIR 画像及び Red Edge 画像を用いることになるため、純粋な RGB 画像からの推定を行うことができない。そこで、この決定木によって生成した画像を教師データとして、pix2pix を用いて、被覆分類の学習を行う。この時の入力は RGB 画像、ラベルは決定木の生成画像である。このようにすることで、実利用の際には RGB 画像のみから土地被覆分類画像を生成することができる。

3.1.2 植生のスペクトル反射特性

樹木や水田などの植生は、近赤外域において特徴的なスペクトル反射特性を示す (図 2)。これは、植物の持つ光合成色素が可視域の電磁波を吸収、近赤外域の電磁波を反射するため起こる。

植物は光合成によってエネルギーを生産している。このとき、植物は光エネルギーを化学エネルギーに変換しているのだが、照射されている光全てを光合成に用いるわけ

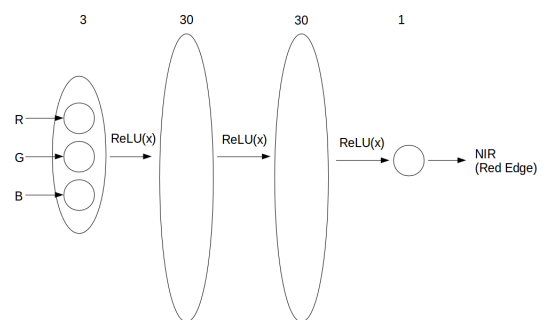


図 4 多層パーセプトロンの層構造

はない。可視域の短波長域と長波長域の成分が光合成に大きく寄与し、可視域の中波長域及び近赤外域の成分はほとんど寄与しない。光合成に用いられなかった光は、葉緑素が反射することになる。

この植物のスペクトル反射特性は、植物の種類及びその活性度によっても異なる (図 3)。一般に、植物の活性度が高いほど、近赤外域の光を強く反射する。NDVI などの植生指標は、この性質を利用して植物の活性度を示している。

3.1.3 回帰による推定の手順

以上より、近赤外画像および Red Edge 画像を推定するための回帰曲線を求める手順は以下の通りとなる。

- (1) RGB 画像及び NIR 画像, Red Edge 画像を入力とし、手作業で作成したラベルを用いて土地被覆分類を行う決定木を作成する。
- (2) 決定木に RGB 画像を入力し、教師データとなる土地被覆分類画像を生成する。
- (3) RGB 画像を入力、生成された画像をラベルとして pix2pix の学習を行う。pix2pix によって生成された土地被覆分類画像を真のものとして扱う。
- (4) 土地被覆分類画像において、植生カテゴリに分類されたピクセルのうち、80 万点をランダムに抽出する。
- (5) これらの点を入力、NIR または Red Edge の値を出力として多層パーセプトロンによる回帰を行う。

ここで用いる多層パーセプトロンのネットワークの構成は図 4 の通りとする。




図 5 U-Net

表 1 ドローンおよびカメラの仕様

ドローン	機種名	Phantom 4 pro (DJI)
カメラ	機種名	Red Edge (Micasense)
	バンド	Blue, Green, Red, Red Edge, NIR
	撮影高度	100 [m]
	画像解像度	1280×960 [px]

表 2 データセットの詳細

名前	撮影日	サイズ	枚数
Day1-1	2018/08/21	256 × 256	645
Day1-2	2018/08/21	256 × 256	720
Day2-1	2018/09/19	256 × 256	750
Day2-2	2018/09/19	256 × 256	645

3.2 DCGAN による近赤外画像および Red Edge 画像の推定

もう一つの方法として、直接 RGB 画像から NIR 画像および Red Edge 画像を推定することを考える。ここでは、DCGAN の一つである pix2pix[13] を用いる。ここでは、2つの画像をペアとして、ネットワークに学習させることで、画像間の関係を学習し、一方の画像からもう一方の画像を生成するものである。

この pix2pix の特徴として、デコードとエンコードの際、図 5 のような、U-Net の構造を用いていることであり、これにより、入力画像と出力画像とで、共通の特徴量を伝搬させることが可能となっている [14]。この特徴により、回帰を用いる手法と同様に、可視画像から近赤外あるいは RedEdge 画像が推定できると考える。

4. 実画像実験

回帰による推定と DCGAN による推定の 2 つを学習させ、実験を行なった。撮影に使用したドローンとカメラを表 1 に示す。撮影は 2 日で、それぞれ 2 回ずつ行っており、そのデータを表 2 に示す。

表 2 において、DayX-Y は X 日目の Y 回目のフライトで撮影された画像であることを示す。また、これらの画像を表 3 のように分け、データセットとして使用した。

表 3 データセットの分割

名前	構成要素	枚数
Day1	Day1-1, Day1-2	1365
Day2	Day2-1, Day2-2	1365
Flight1	Day1-1, Day2-1	1365
Flight2	Day1-2, Day2-2	1365




図 6 各チャネルの画像例. (a) Red. (b) Green. (c) Blue. (d) NIR. (e) Red Edge.

撮影した画像の各チャネルの例を図 6 に示す。

これらの画像を用いて学習を行った両手法に対し、以下の実験を行った。

- 両手法の精度評価
- 植生指標計算への適用

また、このとき、両手法に対して、以下のようにデータを用いて学習及び実験を行った。

- (1) Day1 を用いて学習し、Day2 を用いて評価
- (2) Day2 を用いて学習し、Day1 を用いて評価
- (3) Flight1 を用いて学習し、Flight2 を用いて評価
- (4) Flight2 を用いて学習し、Flight1 を用いて評価

まず、各手法における NIR 画像の推定結果例を図 7 に、Red Edge 画像の推定結果例を図 8 に示す。

4.1 推定画像の精度評価実験

推定された NIR 画像及び Red Edge 画像に対し、

- 絶対平均誤差 MAE
- 信号対雑音比 SNR

の 2 つの指標を用いて評価を行った。それぞれの指標は次の式のように定義する。

$$MAE = \frac{1}{N} \sum_{i,j} |I_g(i,j) - I_t(i,j)| \quad (3)$$




図 7 NIR 画像の推定例. (a) 真値. (b) 回帰による推定. (c) pix2pix による推定.



図 8 Red Edge 画像の推定例. (a) 真値. (b) 回帰による推定. (c) pix2pix による推定.

表 4 NIR 画像推定精度の比較

実験	回帰による推定		pix2pix による推定	
	MAE	SNR	MAE	SNR
1	25.19	12.76	22.14	12.78
2	27.62	12.59	24.89	12.38
3	24.57	12.98	19.63	14.11
4	26.75	12.08	18.78	14.31

表 5 Red Edge 画像推定精度の比較

実験	回帰による推定		pix2pix による推定	
	MAE	SNR	MAE	SNR
1	16.03	13.10	22.14	11.52
2	15.28	13.19	24.89	11.94
3	15.91	13.16	19.63	12.15
4	15.62	12.76	18.78	12.69

ここで、 N は画像の総ピクセル数、 $I_g(i, j)$ は生成画像の (i, j) における画素値、 $I_t(i, j)$ は正解画像の (i, j) における画素値をそれぞれ表す。

$$\text{SNR} = 10 \log_{10} \frac{P_s}{P_n} \quad (4)$$

ここで、

$$P_s = \sum_{i,j} I_t(i, j)^2 \quad (5)$$

$$P_n = \sum_{i,j} (I_g(i, j) - I_t(i, j))^2 \quad (6)$$

とする。

精度評価実験の結果を表 4～表 5 に示す。

表 4 および 5 を見てわかる通り、精度評価実験を行った結果、pix2pix を用いる手法の方がより高精度に推定できることが分かった。この理由として、今回は学習データ及び検証データには同じ柿ほ場で撮影されたデータを用いており、撮影日こそ違うものの、両データの類似度は高く、pix2pix での推定に誤差の発生し辛いデータであったためと考えられる。したがって、今回のデータとは別の柿ほ場の画像を検証に用いた実験を行う必要があると考える。また、回帰を用いる手法の精度が良くなかった原因としては、学習データを作る際のセグメンテーションが挙げられる。本研究では土地被服分類画像を作成し、セグメンテーション結果としていたが、この時の精度が不十分だった可能性がある。土地被服分類画像の精度検証を行う必要がある。また、今回の土地被服分類画像では、柿の木とその他の草木、水田をまとめて一つのカテゴリとして分類を行った。これは、今回用いたマルチスペクトルカメラで撮影できる 5 バンドではうまく分類できなかったためである。しかし、当然これらの植物はそれぞれ固有のスペクトル反射特性を持っていると考えられる。土地被服分類画像をより詳細に作成することで、精度の向上が見込まれる。

また表より、NIR 画像と比べ、Red Edge 画像の方がより精度よく推定されていることが分かる。この原因とし

て、NIR バンドと比べ、Red Edge バンドの方がより可視光域に近く、相関が高かったのではないかと考えられる。

4.2 植生指標への適用実験

次に推定した NIR 画像及び Red Edge 画像を用いて、NDVI と NDRE の計算を行った。計算結果を図 9 および 10 に示す。

図を見てわかる通り、植生指標への適用実験の結果、NDVI については実利用可能な精度での推定を行うことができたと考える。しかし、NDRE については精度よく推定を行えていない部分がある。この原因として、各指標での計算に用いるバンドの違いが挙げられる。NDVI の計算には、Red バンドと NIR バンドを用いる。このうち NIR バンドの画像のみに推定結果を用いた。対して NDRE の計算には NIR と Red Edge のバンドを用いるが、この両方に推定結果を用いた。Red バンドの画像は真値の画像を用いたため誤差を含まないが、NIR と Red Edge の画像は推定結果であるため誤差を含む。そのため、推定結果を二種類含む NDRE が誤差の影響を多く受けたものと考えられる。

5. おわりに

本論文では、RGB 画像を用いた赤外域画像の推定について、2つの手法を提案し、比較実験を行った。ここでは、NIR 画像と Red Edge 画像の 2つを推定対象とし、それらの推定結果を用いて NDVI 及び NDRE の計算を行った。これによって、RGB 画像から植生指標の推定が可能であることを示した。ただし、これは推定結果の目視評価によるものであり、実環境で利用可能かどうかは専門家の確認が必要である。

謝辞 本研究で使用した画像は株式会社サイエンス・クリエイト大橋様、山村様に提供していただきました。ここに両氏に対して感謝の意を表します。

参考文献

- [1] M.E. Brown, J.E. Pinzon, K. Didan, J.T. Morisette, and C.J. Tucker, "Evaluation of the consistency of long-term NDVI time series derived from AVHRR, SPOT-vegetation, SeaWiFS, MODIS, and Landsat ETM+ sensors," *IEEE Trans. Geoscience and Remote Sensing*, Volume 44, Issue 7, Jul. 2006.
- [2] M.P. Labus, G.A. Nielsen, R.L. Lawrence, R. Engel, and D.S. Long, "Wheat yield estimates using multi-temporal NDVI satellite imagery," *Int. J. Remote Sensing*, Volume 23, Issue 20, Nov. 2010.
- [3] 多田 毅, 風間 聡, 沢本 正樹, "NDVI を用いた広葉樹林の蒸発散分布推定," *水文・水資源学会誌*, 7(2), pp.114–119, 1994.
- [4] UM Rao Mogili, B.B.V.L. Deepak, "Review on Application of Drone Systems in Precision Agriculture," *Procedia Computer Science*, Volume 133, pp.502–509, 2018.
- [5] M. Reinecke, T. Prinsloo, "The influence of drone monitoring on crop health and harvest size," *1st Int. Conf. Next Generation Computing Applications (NextComp)*, 2017.
- [6] 田中 圭, 近藤 昭彦, "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稲生育マップの作成 Mapping of Rice Growth Using Low Altitude Remote Sensing by Multicopter," *日本リモートセンシング学会誌*, Volume 36(4), pp.373–387, 2016.
- [7] 農林水産学術会議, "日本型精密農業を目指した技術開発," *農林水産研究開発レポート*, No. 24, 2008.
- [8] <https://www.nhk.or.jp/gendai/articles/4202/index.html>
- [9] D.N.H. Horler, M. Dockray, J. Barber, "The red edge of plant leaf reflectance," *Int. J. Remote Sensing*, 1982.
- [10] MicaSense ケーススタディ, "病気の早期発見におけるレッドエッジバンドの重要性," MicaSens, Inc. 2018.
- [11] 後藤誠二郎, 粟屋善雄, "RapidEye 衛星の Red edge バンドを用いた森林タイプ分類の精度向上に関する検討—岐阜県御嵩町を例として—," *システム農学*, 29 (4), pp.145–153, 2013.
- [12] A. Radford, L. Metz, S. Chintala, "Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks," *ICLR* 2016.
- [13] P. Isola, J.-Y. Zhu, T. Zhou, A.A. Efros, "Image-to-Image Translation with Conditional Adversarial Networks," *CVPR* 2017, Nov. 2016.
- [14] O. Ronneberger, P. Fischer, T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *MICCAI*, 2015.
- [15] <https://www.usgs.gov/land-resources/nli/landsat>

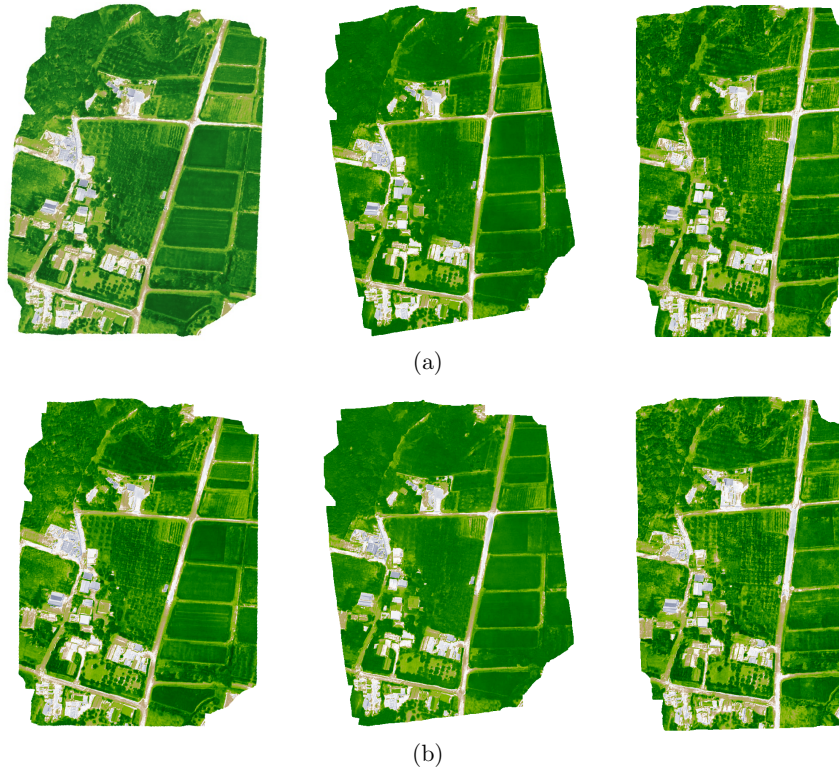


図 9 NDVI の推定例. それぞれ左から真値, 回帰による推定画像を用いたもの, pix2pix による推定画像を用いたもの. (a) Day1. (b) Flight1.




図 10 NDRE の推定例. それぞれ左から真値, 回帰による推定画像を用いたもの, pix2pix による推定画像を用いたもの. (a) Day1. (b) Flight1.