

# 航空写真を用いた機械学習による農地パトロールへの活用可能性の検討

櫻井 淳

## Investigation of Support for Survey of Farmland Use by Machine Learning Using Aerial Photograph

Jun Sakurai

### Abstract

The degradation of farmland has recently become severe because of the aging of farmers and the lack of successors, and its countermeasures are important policy issues. In order to promote the countermeasures, it is essential to understand the situation of degraded farmland. Municipalities and agricultural committees are therefore conducting surveys on farmland use every year. However, as the surveys cover all farmland in a municipality, errors or omissions in the recording of the location of farmland are inevitable even though a great deal of effort is expended for the surveys. This study proposes a machine-learning method for the automatic determination of cultivated and non-cultivated land using aerial photographs and verifies the accuracy of this method. It examines the feasibility and problems of this method to support the surveys of farmland use.

### 1. はじめに

近年、農業従事者の高齢化や後継者不足等により耕作放棄地の増加が深刻化しており、その対策が重要な政策課題となっている。こうした背景から、2014年に「農地中間管理事業の推進に関する法律 [1]」が施行され、全都道府県に農地中間管理機構が設置された。ここでは、高齢化等の理由で耕作できない農地を機構が借り受け、担い手農家に貸し付ける事業が行われている。この制度を推進するためには、農地の実態把握が必要不可欠であることから、各市町村に設置された農業委員会によって、毎年、農地パトロールとよばれる農地の利用状況調査 [2] が実施される。この調査は、2021年度より、市町村部局が実施してきた荒廃農地調査と統合されたことで、農地の荒れ具合に応じて新たな分類方法が定義されている。具体的に、全国すべての農地を対象に、「耕作地」、今後も耕作される見込みがない農地である「1号遊休農地」、周辺地域の農地に比べて利用の程度が著しく劣っている農地である「2号遊休農地」、荒廃度が重度で農地への復元が困難である「再生利用が困難な農地」に分類される。さらに、「1号遊休農地」に関しては、人の背丈以上に生育した雑木の繁茂状態などの基準に基づき、「1号遊休農地（緑区分）」と「1行遊休農地（黄区分）」にわけられ、計5段階に分類される。こうした分類作業は、複数の農業委員による現地調査によって、すべての農地に対して目視判定で行われているが、多大な人的コストを要することや、所在の把握に間違いや漏れが生じる可能性があることが問題視されている。そのため、情報技術などを活用し、

農業パトロールを支援するための枠組みを構築することが望まれている。

関連の既存研究として、農地パトロールは日本独自の取組みであるために、国内における複数の事例が存在する。例えば、福本ら（2016）[3]は、Google ストリートビューの現地写真を用いて荒廃農地を検査する手法を考案しているが、目視確認が必要であり調査を自動化する手法ではないことや、最新年度の写真画像が公開されている場所が少ないことが課題として指摘されている。また、衛星データを用いて荒廃可能性水田の抽出を試みた研究（福本ら、2014）[4]や、航空レーザデータを活用して荒廃可能性農地の把握を試行した研究（塚原ら、2020）[5]がある。これらは、画像処理によって荒廃の可能性がある農地の検出を目指したものである。しかし、衛星データや航空レーザデータは航測会社などから購入する必要があるため、非常に高価かつ測定時期が限定されるため、各自治体が調査時期に見合ったデータを入手することは限りなく困難と考えられる。さらに、神奈川県モデル事業（株式会社四門、2020）[6]として、ドローンの空撮画像を用いた荒廃農地調査が提案されているが、空撮画像から荒廃農地を目視で判別可能であるかを試行したものであり、自動化手法の確立までには至っていない。これらの課題を解決するため、著者は、航空写真を用いて耕作状況を自動判定する手法のプロトタイプを考案[7][8]してきた。

本研究では、無償で公開されている航空写真を用いて、機械学習による耕作地と不耕作地の自動判定手法の提案と精度検証を行い、農地パトロールの支援に向けた活用可能性と課題を検討する。

## 2. 研究概要

本研究では、航空写真を用いて機械学習による耕作地・不耕作地の自動判別手法を提案する。本研究の処理の流れは、図1に示すように、データ生成部、学習部、推定部に大別される。これらの処理の詳細を次に記述する。




図1 処理の流れ

### 2.1. 作業環境および使用データ

本研究の作業環境として、データ生成部ではQGIS3.16を使用し、GISの各種機能を活用してデータの生成・加工を行った。また、機械学習部と推定部では、ブラウザ上でPythonコードの記述、実行が可能なGoogle Colaboratory Proを使用し、機械学習ライブラリのTensorFlowとKerasを用いて処理を行った。本研究で使用するデータを図2に示す。



全国農地ナビ



筆ポリゴンおよび国土地理院の航空写真

図 2 使用データ

まず、対象農地が耕作地か不耕作地であるかを判定する正解データには、農林水産省の eMAFF 農地ナビ [9] で公表される農地情報を用いた。このサイトでは、各農地に対する過去の利用状況調査結果が集約されており、本研究ではこのサイト上でラベル付けされた「遊休農地ではない」を耕作地、「遊休農地（不耕作）」を不耕作地と定義した。次に、農地の区画を区分するデータとして、農林水産省の筆ポリゴン [10] とよばれる農地の区画情報を使用した。さらに、航空写真データとして、国土地理院が提供する地理院タイル [11] の内、全国最新写真（シームレス）のズームレベル 18 を活用した。

## 2.2. データ生成部

データ生成部は、図 3 に示すように、不耕作農地の属性情報入力、耕作・不耕作ポリゴンの生成、耕作・不耕作画像の生成の 3 種類の作業と、画像鮮明化処理から構成される。



図 3 データ生成部の流れ

まず、1つ目の作業では、筆ポリゴンの属性情報に不耕作の判定結果の入力欄を追加する。そして、農地ナビの Web サイト上で遊休農地（不耕作）の場所を目視で確認し、対象の筆ポリゴンに不耕作地の判定結果を追加する。なお、本研究では、それ以外を耕作地と定義する。次に、2つ目の作業では、QGIS の属性によるレイヤ分割機能を使用し、耕作と不耕作に分類された各区画の筆ポリゴンを生成する。そして、3つ目の作業では、QGIS のマスキレイヤによる切り抜き機能を用いて、耕作と不耕作それぞれの各ポリゴンの範囲で切り抜かれた航空写真の画像を生成する。

これらに加えて、画像の判定精度を向上させることを目的に、前処理として画像鮮明化処理を行った。具体的に、ディープラーニングによる画像鮮明化技術の一つである Real-ESRGAN[12] を使用した。これは、ぼかしやノイズをかけた画像を訓練させ、低解像度の画像を高解像度化する技術の一つである。また、学習モデルには、事前学習済みモデルの RealESRGAN\_x4plus を用いて、元画像の4倍の大きさの画像を生成した。処理結果の例を図4に示す。



図4 画像鮮明化処理の処理結果例

### 2.3. 学習部および推定部

前述のデータ生成部で生成した耕作と不耕作の画像を元に、学習用の教師データと推定用の評価データに分類する。学習部では、まず、画像拡張処理により、元画像に対して-20度から20度まで5度ずつ傾けた画像に拡張する。次に、学習処理により、深層学習の手法の一つである畳み込みニューラルネットワーク（以下、CNN）を用いて教師データの学習を行う。なお、元の入力画像のサイズが小さいことから、入力画像は64×64の3チャンネルに設定し、モデル構造は畳み込み層4層、全結合層2層とする。また、推定部では、学習部で生成した学習モデルを用いて、評価データの結果を推定し、耕作か不耕作かを判定する。

## 3. 評価実験

評価実験では、提案手法の判定精度を検証する。具体的に、使用する航空写真の違いの影響を検証する「実験Ⅰ）航空写真の違いによる判定精度の検証」と、GANによる画像鮮明化処理の影響を検証する「実験Ⅱ）画像鮮明化処理による判定精度の検証」の2種類の実験を実施した。以下に、それらの概要と結果を記述する。

### 3.1. 実験Ⅰ）航空写真の違いによる判定精度の検証

#### 3.1.1. 実験概要

本実験では、画像鮮明化処理の影響を除外するため、画像鮮明化処理を除いた提案手法を用いて、2種類の航空写真により耕作・不耕作の推定精度を評価し、自動判別の可能性を検証した。

実験データには、国土地理院の航空写真の比較対象として、QGISのXYZ Tilesプラグインを使用して取得可能なGoogle社が提供する航空写真（Google Satellite）を使用した。

評価手順として、まず、神奈川県を対象に不耕作ポリゴンを収集し、畑が802個、田が431個を抽出した。次に、それらの不耕作ポリゴン以外を耕作と定義し、同じ数の耕作ポリゴンを抽出した。そして、耕作・不耕作それぞれ100個を評価データ、それ以外の702個と331個を学習データとし

て学習と推定を実施した。なお、評価データは交差検証を 4 回繰り返すことにより、耕作・不耕作それぞれ 400 個の画像を推定した。その結果を適合率、再現率、F 値で評価した。

### 3.1.2. 実験結果





まず、畑の評価結果を表 1 に示す。

表 1 畑の評価結果

種類	国土地理院						Google Satellite						
	全数	推定数	正解数	適合率	再現率	F 値	種類	全数	推定数	正解数	適合率	再現率	F 値
耕作	400	472	369	0.78	0.92	0.85	耕作	400	462	336	0.73	0.84	0.78
不耕作	400	328	297	0.91	0.74	0.82	不耕作	400	330	274	0.83	0.69	0.75
合計	800	800	666	0.83	0.83	0.83	合計	800	792	610	0.77	0.76	0.77

この結果から、F 値に着目すると、Google Satellite が 0.77 に対し、国土地理院が 0.83 であり、国土地理院のほうが高い判定精度であることがわかる。また、国土地理院の不耕作の適合率が 0.91 であるため、システムで推定した不耕作の結果は、90% 以上が正しく判定ができていたことがわかった。このことから、一定の精度は確保できたものの、2 割程度の判別に失敗した。その原因の調査のために、国土地理院の結果を抜粋した画像を表 2 に示す。

表 2 畑の評価結果抜粋（画像：国土地理院の航空写真）

		農業委員会などの調査結果（正解データ）	
		耕作（不耕作以外）	不耕作
システム の 予測 結果	耕作		
	不耕作		

これらの画像から、調査上は耕作地であるが不耕作と判定した事例では、木々が生い茂っていることがわかる。また、調査上は不耕作地であるが耕作と判定した事例では、規則的に木々が配置されている状況であった。これらに対しては、調査時期と撮影時期の不一致の影響によって、現況とは異なる調査結果になっている可能性が考えられる。

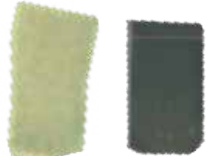



次に、田の評価結果を表 3 に示す。

表 3 田の評価結果

国土地理院							Google Satellite						
種類	全数	推定数	正解数	適合率	再現率	F 値	種類	全数	推定数	正解数	適合率	再現率	F 値
耕作	400	348	218	0.63	0.55	0.58	耕作	400	376	219	0.58	0.55	0.56
不耕作	400	452	270	0.60	0.68	0.63	不耕作	400	424	243	0.57	0.61	0.59
合計	800	800	488	0.61	0.61	0.61	合計	800	800	462	0.58	0.58	0.58

この結果から、F 値に着目すると、Google Satellite が 0.58 に対し、国土地理院が 0.61 であり、畑と同様に国土地理院のほうが高い判定精度であることがわかる。ただし、畑よりも全体的に判定精度が低い結果となった。具体的に、国土地理院の結果を抜粋した画像を表 4 に示す。

表 4 田の評価結果抜粋(画像:国土地理院の航空写真)

		農業委員会などの調査結果 (正解データ)	
		耕作 (不耕作以外)	不耕作
システムの 予測結果	耕作		
	不耕作		

これらの結果から、耕作と正しく判定した画像は水を張って単色となっているものが多く、不耕作と判定した画像は植生の影響で全体的に緑色模様のもが多く確認された。一方で、実際には耕作地であるが不耕作と判定した事例では地面が露出しており、実際には不耕作地であるが耕作と判定した事例では画質が粗く植生状況を判読できないものが目立った。これらに関しても、畑と同様に調査時期と撮影時期の不一致、撮影時期が異なることによる季節の違いの影響や、航空写真の解像度や輝度の違いなどが影響している可能性が考えられる。

### 3.2. 実験 II) 画像鮮明化処理による判定精度の検証

#### 3.2.1. 実験概要

本実験では、GAN の画像鮮明化処理を含む提案手法を用いて、自動判別精度の向上の可能性を検証した。実験 I と同様の国土地理院の航空写真を用いて、畑が 802 個、田が 431 個のデータを対象とした。そして、耕作・不耕作それぞれ 100 個を評価データ、それ以外の 702 個と 331 個を学習データとして学習と推定を実施した。なお、評価データは交差検証を 4 回繰り返すことにより、耕作・不耕作それぞれ 400 個の画像を推定し、それらの結果を適合率、再現率、F 値で評価した。

#### 3.2.2. 実験結果

畑の評価結果を表 5、田の評価結果を表 6 に示す。

表 5 畑の評価結果

GAN の画像鮮明化処理を用いない場合							GAN の画像鮮明化処理を用いた場合						
種類	全数	推定数	正解数	適合率	再現率	F 値	種類	全数	推定数	正解数	適合率	再現率	F 値
耕作	400	472	369	0.78	0.92	0.85	耕作	400	503	370	0.74	0.93	0.82
不耕作	400	328	297	0.91	0.74	0.82	不耕作	400	297	267	0.90	0.67	0.77
合計	800	800	666	0.83	0.83	0.83	合計	800	800	637	0.80	0.80	0.80

表 6 田の評価結果









GAN の画像鮮明化処理を用いない場合							GAN の画像鮮明化処理を用いた場合						
種類	全数	推定数	正解数	適合率	再現率	F 値	種類	全数	推定数	正解数	適合率	再現率	F 値
耕作	400	348	218	0.63	0.55	0.58	耕作	400	378	234	0.62	0.59	0.60
不耕作	400	452	270	0.60	0.68	0.63	不耕作	400	422	256	0.61	0.64	0.62
合計	800	800	488	0.61	0.61	0.61	合計	800	800	490	0.61	0.61	0.61

これらの結果から、画像鮮明化処理を行わない場合の F 値が畑で 0.83、田で 0.61 に対して、行った場合の F 値が畑で 0.80、田で 0.61 であるため、差異はほぼない結果となった。よって、本研究の処理によって画像を鮮明化することの効果はみられなかった。なお、本研究で使用したデータセットは土地の形状に特化したものではないため、農地用のデータセットを自前で構築し、畝の起伏などの境目を強調することで、精度向上の可能性があるかを検討することは今後の課題である。また、誤判定した結果の原因と対策を検討するため、誤判定の航空写真に対して、目視確認で想定される原因の分類を行った。その整理結果を表 7 に、個別の結果を抜粋したものを表 8 に示す。

表 7 誤判定画像の目視確認結果

判定結果		No	枚数	想定される原因
畑	耕作を不 耕作と誤 判定	A	11	樹木が密集 or 一部存在
		B	1	不耕作の状態
		C	18	その他 (原因不明含む)
	不耕作を 耕作と誤 判定	D	70	樹木が密集 or 一部存在
		E	28	耕作されている状態
		F	35	その他 (原因不明含む)
田	耕作を不 耕作と誤 判定	G	32	水無し or 植生多い状態
		H	71	畦畔 or 稲架掛けが存在
		I	63	その他 (原因不明含む)
	不耕作を 耕作と誤 判定	J	45	水無し or 植生多い状態
		K	99	水が張っている状態
		L	0	その他 (原因不明含む)

表 8 個別の結果例 (表 6 の原因 A-L と対応)

	畑		田	
	不耕作と誤判定	耕作と誤判定	不耕作と誤判定	耕作と誤判定
誤判定の原因	原因 A	原因 D	原因 G	原因 J
航空写真の 使用画像				
Google ストリートビュー				

これらの結果より、畑では、耕作と不耕作の画像ともに、樹木が生えている画像が多い (原因 A, D) ことがわかった。1章で述べたように、現行の農地パトロール業務においては、雑木の高さや密集度によって遊休農地を細分化する必要がある。そのため、これらを正しく判定するためには、ドローンの空撮画像から写真測量技術によって生成できる3次元データを活用し、樹木の有無や高さの自動判定手法を構築することが一案として考えられる。

一方、田では、耕作している土地でも時期によって裸地の場合 (原因 G)、耕作中の稲架掛けや水田境目の畦畔が存在する場合 (原因 H)、不耕作の裸地で画像上の濃淡がなくなり水が張っている状態との判別が困難な場合 (原因 J) や、不耕作でも水が張っている場合 (原因 K) などが確認



された。以上より、実験 I と同様に、季節によって航空写真による見え方が大きく異なることが影響していると考えられるため、時期を統一した画像で学習モデルを生成する必要がある。また、本研究で使用した農地情報は調査年にばらつきがあるため、農地情報と航空写真の時期を合わせたデータを活用する必要性が高いことが課題として挙げられる。

#### 4. おわりに

本研究では、国土地理院と Google 社が提供する航空写真を用いて、画像鮮明化処理を取り入れた機械学習による耕作地と不耕作地の判別手法を提案し、その判別精度を検証した。その結果、以下の知見などが得られた。

- ・国土地理院と Google の航空写真をそれぞれ用いた場合の判定精度を比較した結果、国土地理院のほうが、畑の F 値が 0.83、田の F 値が 0.61 と高い判定精度を示したこと
- ・前処理として Real-ESRGAN による画像鮮明化技術を取り入れた結果、畑の F 値が 0.80、田の F 値が 0.61 の結果となったことから、画像鮮明化技術による影響はほぼみられなかったこと

以上のことから、無償の航空写真を用いた場合でも、耕作地と不耕作地の自動判別に向けた機械学習の活用可能性を一定程度示せたと考える。ただし、本研究では、耕作と不耕作の正解データの作成に関して、農地情報をもとに機械的に分類したため、農地パトロールの調査時期や航空写真の撮影時期などを考慮していないことが精度に影響している可能性が高い。また、現行の要領では 5 種類の分類が必要であるが、本研究では耕作と不耕作の簡易的な 2 種類の分類に留まっている。これらの課題を踏まえて、今後、自治体の協力を得て各年度の農地パトロールの調査結果と、より高解像度の航空写真を入手し、実務利用に向けた精度向上を行う予定である。また、ドローンを活用して即時的に農地の利用状況を把握することや、写真測量技術を用いて雑木の高さ推定などを行うことによって現行の農地パトロール要領に対応した手法を構築することを目指す。

#### 参考文献

- [1] 農林水産省：農地中間管理事業の推進に関する法律、<[https://www.maff.go.jp/j/keiei/koukai/kikou/kikou\\_law.html](https://www.maff.go.jp/j/keiei/koukai/kikou/kikou_law.html)>, (入手 2023.5.16).
- [2] 全国農業委員会ネットワーク機構，一般社団法人全国農業会議所：農地パトロール（利用状況調査）実施要領，2021.
- [3] 福本昌人，進藤惣治：Google Earth を活用した荒廃農地調査による荒廃農地の所在把握結果の検査手法，農村工学研究所技報，No. 218，pp. 19-28，2016.
- [4] 福本昌人，吉迫宏：多時期の衛星データと水田区画データを用いた荒廃農地調査の踏査対象田のスクリーニング手法，農業農村工学会論文集，Vol. 82，No. 5，pp. 339-346，2014.
- [5] 塚原正之，太田望洋：航空レーザデータを活用した荒廃農地の把握，<[https://www.ajiko.co.jp/dl\\_data/pdf\\_ff2020/p64-65.pdf](https://www.ajiko.co.jp/dl_data/pdf_ff2020/p64-65.pdf)>, (入手 2023.5.16).
- [6] 株式会社四門：ドローン前提社会の実現に向けたモデル事業実施報告書 ドローンを活用した荒廃農地調査，<[https://www.pref.kanagawa.jp/documents/67972/02\\_nouti.pdf](https://www.pref.kanagawa.jp/documents/67972/02_nouti.pdf)>, (入手 2023.5.16).
- [7] 櫻井淳：機械学習を用いた航空写真からの荒廃農地の判別に関する研究，第 20 回情報科学技術フォーラム講演論文集，Vol. 20，No. 3，pp. 119-120，2021.

- [ 8 ] 櫻井淳：GAN を用いた航空写真からの荒廃農地の判定に関する研究，第 21 回情報科学技術フォーラム講演論文集，Vol. 21，No. 4，pp. 307-308，2022.
- [ 9 ] 農林水産省：eMAFF 農地ナビ，<<https://map.maff.go.jp>>，（入手 2023.5.16）.
- [10] 農林水産省：農地の区画情報（筆ポリゴン），<<https://www.maff.go.jp/j/tokei/polygon>>，（入手 2023.5.16）.
- [11] 国土地理院：地理院タイル，<<https://maps.gsi.go.jp/development/ichiran.html>>，（入手 2023.5.16）.
- [12] Wang, X., Xie, L., Dong, C. and Shan, Y.: Real-ESRGAN: Training Real-World Blind Super-Resolution with Pure Synthetic Data, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) Workshops*, pp. 1905-1914, 2021.