

Title	深層学習による衛星画像認識を活用した土地利用の推計結果について
Author(s)	神宮司, 一誠; 飯山, 将晃; 山口, 幸三; 吉田, 嘉雄; 仙田, 徹志
Citation	Working Paper Series (2019), 9: 1-13
Issue Date	2019-09
URL	http://hdl.handle.net/2433/244168
Right	Copyright (C) 2014 Academic Center for Computing and Media Studies, Agricultural Economics and Information Laboratory, Kyoto University. All Rights Reserved
Type	Research Paper
Textversion	publisher

*STATISTICAL DIGITAL ARCHIVE OF
AGRICULTURE, FORESTRY AND FISHERIES*



Working Paper Series No.9

深層学習による衛星画像認識を活用した
土地利用の推計結果について

神宮司一誠 飯山将晃
山口幸三 吉田嘉雄
仙田徹志

WORKING PAPER SERIES

学術情報メディアセンター
食料・農業統計情報開発研究分野

Working Paper Series No.9

深層学習による衛星画像認識を活用した
土地利用の推計結果について

神宮司一誠 飯山将晃
山口幸三 吉田嘉雄
仙田徹志

2019年9月

京都大学 学術情報メディアセンター

Academic Center for Computing and Media Studies,
Agricultural Economics and Information Laboratory

本 Working Paper は、京都大学 学術情報メディアセンター 「農林水産統計の高度利用に関する研究専門委員会」のプロジェクト研究として実施された研究成果を公表するためのものである。

深層学習による衛星画像認識を活用した土地利用の推計結果について

1. 本研究の背景－土地利用調査におけるパターン画像認識技術の必要性－

農作物の作付面積等の土地利用を推計するための手法のひとつに「ドット標本調査法」があることは古くから知られていたが、それは地図や写真図を利用した手法であった。神宮司らは 2011 年以來、これを Google Earth を利用して実施する手法について検討してきた。それは、Google Earth 画像上の調査対象地域内（例えば、国、県、市町村レベル）に緯度と経度を格子状に組み合わせて作成した標本地点を配置し、それらの地点における土地利用状況を属性調査法で現地調査し、調査対象地域全体における属性別土地利用面積を推定しようとするものである。しかし標本地点における現地調査に先立って、現地調査の効率化を図る観点から、予め現地調査に行くべきところか否かの判断を行う準備調査として、Google Earth 画像上で各標本地点について耕地本地か否かの判定を行うこととしている。この作業過程の中で、現地調査に時間がかかるのは止むを得ないとしても、Google Earth 画像上の調査対象地域内の全ての標本地点について、準備作業として耕地本地か否かを手作業で判定していくことは単調で、多くの時間も要することから改善の余地がないかが課題となっていた（図 1）。こうした課題を解決する方法として、近年、発達してきている深層学習による画像認識技術の活用があげられる。本研究は、こうした背景を踏まえ、京都大学寄附講座「農林水産統計デジタルアーカイブ講座」において 2018 年度のプロジェクト研究の一部として取り組むこととなったものである。

2. 画像判読システムの開発の課題と方法

以上の背景を踏まえ、本稿では、深層学習による画像認識技術を導入した土地利用推計の精度の検討を行い、その上で、新たな土地利用推計の調査法の改善に向けた提案を行うことを目的とした。ここで開発した画像の自動判定技術の概要は、緯度と経度の組合せで作成された標本地点を中心に置いた正方形の画像（高度 300m 程度から見た 150m×150m の広さの画像）を切り取り、その切り取られた画像について耕地本地か否かを判定しようとするものである。この判定を行うため、まず、予め収集した約 5,000 枚の画像とその画像の中央地点（ドット標本調査地点）に対応する耕地本地か否かの情報を教師データとして用い、画像認識の分野で用いられている「畳み込みニューラルネットワークによるクラス識別器」を構築した。この構築したクラス識別器に、調査対象地域における調査地点の画像を読み込ませて、各画像について耕地本地である尤度（0～1 の値）が計算できるようにした。この尤度に基づき、尤度が 0.5 を超えるものを耕地本地、それ以下のものを非耕地本地として判別することとした。

図 2 は、深層学習法による土地利用の判別処理工程をイメージとして図示したものである。図 3 は、上記のように教師データを用いて構築した「畳み込みニューラル

ネットワークによるクラス識別器」の部分のイメージ図である。ここで用いた教師データ数は約 5,000 であった。図 4 は、調査対象地域において、緯度・経度で指定した調査地点について、上のように構築した「畳み込みニューラルネットワークによるクラス識別器」で耕地本地らしさを尤度で判定表示するイメージ図である。このクラス識別器を使って、表 1 に示した日本国内の 10 の調査対象地域の 13,700 地点について Google Earth 上での判別調査を行った。

なお、この深層学習法による土地利用判別の研究を始めた当初（2018 年 2 月頃）は、我が国における耕地面積調査と同様に耕地種別（田畑別）、本地、畦畔別に推計でき、更には耕作放棄地（荒地）も区分できるのではないかと考えていた。しかし、それを可能にするためには相当な量の教師データの色分け編集加工等を行わなければならないことから、今回の深層学習法による推計では、単純に耕地本地か非耕地かを判別することにした（2018 年 6 月）。この判別調査は、10 の調査地域で行い、標本規模は約 13,700 地点であった。これらの調査地点では、同時にドット標本調査法による目視判定調査も行い、この両者の結果を比較するとともに、農林水産省の公式統計値とも比較した。この調査における推計値は、次項以降に示されるように、これらの統計値に非常に近似していた。

3. 試行調査の具体的結果及び考察

1) 調査結果の概要

上記のような課題と方法の下で実施した試行調査の結果については、まず、各調査対象地域における耕地本地面積率を推計し、表 1 のように取りまとめた。

この表 1 は、深層学習法による耕地本地面積率の推計結果とドット標本調査値及び農林水産省公表値とを比較検討しやすいように、10 の調査対象地域で行った調査結果を総括的に整理したものである。ここで明らかになっているように、深層学習法による推計結果は、調査手法としては他と全く異なっているにもかかわらず、客観的にみれば全体的には各地域とも他の手法による推計値と驚くほど近似したものとなっている。特に 10 地域全体の平均値でみると、標本規模の増大効果も相俟って、生じていた誤差は土が相殺され、他の手法による推計値と完全に一致したものとなっている。この表を見る限りでは、深層学習法による推計の信頼性はかなり高いものと判断される。

2) 尤度の分布状況

表 2 は、深層学習法において、全国を調査対象とした時の標本地点（表 1 の第 1 行目参照）における耕地本地らしさを示す指標である尤度の計算値の分布状況についてドット標本調査結果とクロスさせてみたものである。尤度は 1 に近づく程、非耕地ではなく耕地本地らしい地点とされ、既に説明したように尤度が 0.5 を超える値となった地点を耕地本地とした。ちなみにこの 0.5 を閾値とした時の耕地本地の分布比率が 11.5% となっており、これは表 1 でもみたように農林水産省の耕地本地率と一致する推計値が得られたことになっている。他の調査対象地域においても推計値は異なるも

の、分布の形としてはこのようになっている。このような分布型になるのは、調査地点における土地利用を面的にとらえながらも非耕地か耕地本地かの属性調査法として調査したためである。理想的には、目視調査結果が非耕地で尤度が 0.6 から 1.0 にある 50 の標本は、尤度が 0.1 から 0.5 の間に分布してくれることが望ましく、また目視調査結果が本地で尤度が 0.1 から 0.5 の間に分布する 59 の標本は、尤度が 0.6 から 1.0 の間に分布してくれるのが望ましいといえる。妥当な推計値を得るために閾値をどこに設定して判別するかも一つの検討課題になりうるが、この研究調査の中では、他の調査対象地域の場合を含めて閾値はすべて 0.5 として判別し、耕地本地率の計算を行った。

この表を更に分かりやすくするために集計加工した表が次の項に示す表 3 である。

3) 深層学習法の判読結果とドット標本調査法による目視判定結果の分析

このような画像判読による土地利用統計作成や土地利用被覆図の作成結果の精度分析を行う場合、各標本地点での判定結果と実測調査結果をコンフュージョンマトリックスの形に取りまとめ、判定の正確性を分析することが多い。表 3 は、その例に倣って、深層学習法の判読結果とドット標本調査法での目視判定結果を尤度値との関係も検討できるようにする目的で作成したものである。内容的には、表 2 を集約集計した表になっている。

この表 3 について、まず、深層学習法によって、非耕地と判定されたグループ 870 地点について、ドット標本調査結果から得られた目視調査の結果を見てみると、その中の 800 地点が非耕地と判定されたものの、残り 70 地点のうち 59 地点は耕地本地、6 地点が畦畔、5 地点が耕作放棄等と判定されている。非耕地についての判定精度は、92.0%になっている。これは比較的高い一致率が得られたと評価できる。同様に耕地本地についてみると、深層学習法では 113 地点が耕地本地と判定されているが、ドット標本調査法による目視調査で確認するとそのうちの 56 地点が耕地本地と判定され、残り 57 地点のうち 50 地点が非耕地、2 地点が畦畔、5 地点が耕作放棄等と判定されている。耕地本地についての判定精度は 49.6%となっている。これはあまりいい判定精度ではない。全体で見ると、有効標本規模（有効調査地点数）983 地点のうち非耕地で一致したのが 800 地点、耕地本地で一致したのが 56 地点で、合計としては 856 地点での判定が一致し、この一致率は 87.1%であった。総合すると、全体としては、比較的高い一致率が得られたが、肝心の耕地本地においてはあまりいい判定精度が得られなかったという結果になった。この判定精度を向上させるために本研究では、当初の教師画像データを裏返しにして追加したり、切り取り画像の大きさを変えたりしてみたが、これらにより大きく判定精度を向上させることはできなかった。

深層学習法における判読結果は、目視調査結果と一致して欲しいと考えられるが、ここにおける深層学習法の判定結果は必ずしもドット標本調査地点の目視判定結果と個々には一致しないものになった。どのようなケースの時に両者の判定が異なったのか事例的に調べてみると、例えば、図 5 のように、ピンの位置についての土地利用属性は目視判読では明らかに耕地本地であっても非耕地となっていたり（このような誤判定は、115 中 59 例あった）、逆に図 6 のように、明白に非耕地であっても耕地本地

になったりしているところがあった（このような誤判定は、850 中 50 例あった）。更に山影や木蔭の部分に標本が当たり、人間の目視でも判定に迷う状況になっているようなところでは、深層学習法による判定も難しかったものと考えられるところもあった。今回調査対象地域は全部で 10 調査地域あったが、残りの 9 調査地域でも同様の傾向となっている。何故このようなことが生じるのかについては、深層学習法の構造がブラックボックスになっているようで、メカニズム的にはよく分からないというのが現状である。他の研究機関等でもこのような事例はよく起きており、その原因と対策についてはまだよく分かっていないようである。ちなみに余談かも知れないが、深層学習法に関する研究者の話によれば、人間の目による点の地点における目視判定能力は、連続作業には飽きてきたり疲れてきたりする弱点があるものの、周囲の状況などを含めて判断する能力は深層学習法など機械判定法に比べるとまだまだはるかに優れているものらしい。

このようなことが生じた大きな原因は、目視判定結果は標本地点における「点」での調査に基づくものであり、深層学習法による判定は標本地点を中心に置いた正方形の面としての「地点」で判定したことに由来しているとも考えている。

しかし、一方において、このような判定誤差があっても全体としてみれば、それらが確率的に相殺されて、有効標本規模 983 の地点のうち 870 地点が非耕地と判定され、113 地点が耕地本地と判定され、全体としては、上述したとおり農林水産省が推定している母集団における耕地本地の割合(11.5%)に近似し、ほぼ正確に推定できているという興味深い性格を持つ調査手法となっていることが分かった。

4) 判定精度に関する関連研究との比較

これまで、土地利用被覆図作成については研究機関や大学などで数多くの研究事例があるが、ここではウェブサイトから入手した JAXA と株式会社パスコの研究調査結果を表 4 として取りまとめ、これと今回実施した京都大学での深層学習法による調査結果を比較してみた。土地利用区分数、調査対象地域、調査対象地点数などはそれぞれ異なっているが、精度（調査地点における GT データとの一致率）では、本研究における全国一本の場合は 87.1%を確保しており、JAXA の 81.6%、株式会社パスコの 82.8%を上回っていることが分かった。

5) 処理時間について

深層学習法による調査手法の開発目的のひとつに、ドット標本調査法では画像の判別作業に時間がかかることから、それが改善できないかということがあった。これについては、例えば 1 調査対象地域 1,000 標本規模の判読調査にはチェック調査等を含めると 2 日程度はかかるが、これを深層学習法で調査すると、判読作業そのものに限定すれば僅か 2、3 分でできることが確認された。これは大きな負担軽減になると思われた。しかし、既に指摘したようにドット標本調査法と深層学習法による調査方法とでは、判読作業内容が大きく異なり、深層学習法による画像の判読精度がまだ低いことから、今の段階では、この処理時間の速さはドット標本調査法の改善に直接的に資することはできないでいると考えている。

4. 要約

本稿では、深層学習法における画像認識技術や衛星画像などを利用した土地利用統計調査方法について検討を行った。本稿の研究成果は、以下の七点にまとめられる。

第一に、2018年度に、深層学習法による衛星画像認識を活用した土地利用の推定を行うシステム「畳み込みニューラルネットワークによるクラス識別器」を構築した。

第二に、システムの構築に当って、教師画像データとしては、ドット標本調査結果で得られていた緯度と経度を組み合わせた「点」地点での属性データ(約 5,000 地点)を用いた。深層学習法における判読については、その「点」地点の判読ではなく点を中心に置いた正方形(150m×150m)の「面」地点での判読法とした。判読結果としては、耕地本地らしさを0～1の尤度で表示することとし、0.5を超えるものを耕地本地、0.5以下を非耕地とした。

第三に、このシステムを用いて、全国、全国農業地域(東北、北陸、近畿)、関東地方での主要県等、10の調査対象地域で耕地本地面積を推定する試行調査を行った。全体としての標本規模は、約 13,700 標本であった。

第四に、深層学習法で構築したシステムによる土地利用判読処理速度の速さには著しいものがあった。手作業では何日もかかる作業を一瞬で完了することができた。

第五に、試行調査による耕地本地面積の推計結果は、10の全調査対象地域とも農林統計値、ドット標本調査法による推計値に驚くほど近似した。

第六に、一方、個々の標本地点における判別結果と目視判定結果の一致度は、87%程度で高い一致率であったが、個々の地点における不一致の画像等をみるとまだ信頼に足るものではなかった。また、この判別精度を向上させるためには、更に時間をかけた工夫と研究が必要とされた。これらのことから、今回の取り組みだけではドット標本調査における準備調査の効率化を図るという当初の課題については応えることができなかった。

第七に、しかしながら、構築した深層学習による画像判定システムの判定精度は、他の研究機関等で開発された土地利用調査における判読精度を上回っていた。このことは判定項目数が少ないことが影響しているかも知れないが、使い方によってはこれまでの伝統的な調査手法に基づく調査結果の妥当性を検証できる調査手法である可能性があり、同時に、新たな独立的な土地利用統計調査手法としての有効性が示唆されているとも考えられた。

なお、判別手法に関して、本研究では、深層学習手法として画像からのクラス識別手法を採用したが、他のアプローチとして深層学習を用いた画像の領域分割(セマンティックセグメンテーション)も有効であると考えられる。教師データとして画像の各画素毎に耕地・非耕地等の正解を与える必要があり、クラス識別の場合と比較しても教師データの準備に多大な手間がかかるが、その問題がクリアできれば有効な手法となる可能性が高いと考えられる。この点については、今後の課題とする。

【付記】

本稿は、2018年9月に開催された統計関連学会連合大会において口頭発表した内容を基にして今般ワーキングペーパーとして取りまとめたものである。また、本稿は、京都大学寄附講座「農林水産統計デジタルアーカイブ講座」におけるプロジェクト研究の一部であり、画像認識プログラム作成には飯山研究室の学生の多大な協力を得た。記して感謝申し上げます。

【参考文献】

JAXA「高解像度土地利用土地被覆図ホームページ」

http://www.eorc.jaxa.jp/ALOS/lulc/lulc_jindex_v1803.htm

株式会社パスコ 伊東里保ら(2016)「ディープラーニングを適用した衛星画像からの土地被覆分類手法の評価」

奥村俊夫(2018)「リモートセンシング技術におけるAI活用に向けた取組み」

https://www.restec.or.jp/ja/wp-content/uploads/2018/06/R_20180613-05.pdf

大野裕幸(2017)「AIを活用した地物自動抽出に関する研究」

<http://www.gsi.go.jp/common/000189417.pdf>

齋藤元也ら(2017)「日本における農業リモートセンシング研究の軌跡」

https://www.jstage.jst.go.jp/article/rssj/37/3/37_193/_pdf/-char/ja

片木仁ら(2016)「JAXA日本域高解像度土地利用・土地被覆図の高精度化」

http://www.eorc.jaxa.jp/ALOS/lulc/documents/2016_1102_RSSJ_Katagi_final_web.pdf

(株)パスコ「小型衛星群等によるリアルタイム地球観測網システムの研究開発」

http://www.meti.go.jp/policy/tech_evaluation/e00/03/h24/466.pdf

石塚直樹「マイクロ波衛星画像と地理情報システムを利用して水稲作付け地を高い精度で推定する」

http://www.naro.affrc.go.jp/archive/niaes/techdoc/inovlec2006/4_ishitsuka.pdf

齋藤康毅(2016)「ゼロから作るDeep Learning」オーム社

フランク・イェーツ著、大沢・渡部・広田・石田訳(1952)「標本調査論」東洋経済新報社

齊藤昭(2013)「農の統計にみる知のデザイン」農林統計出版

神宮司一誠(2014)「Google earth を利用したドット標本調査法による土地利用面積調査について」法政大学オケージョナル・ペーパー44号

https://www.hosei.ac.jp/toukei/shuppan/g_oc44.pdf

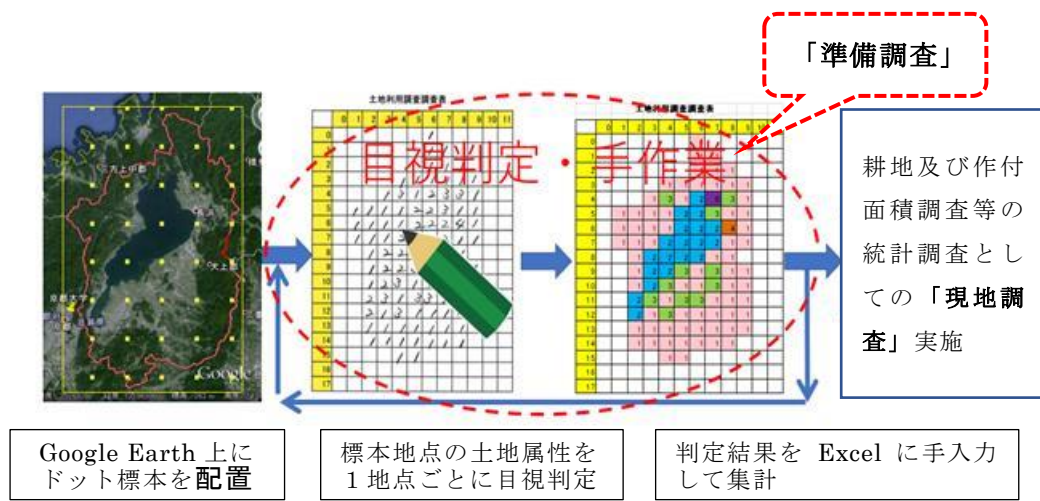


図1 ドット標本調査法における準備調査段階での作業工程図（滋賀県）

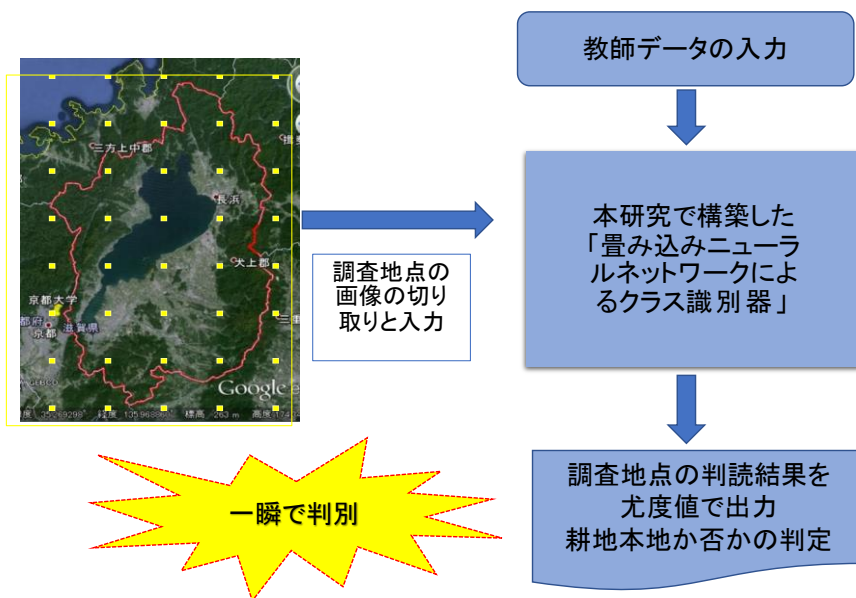


図2 深層学習法による判別処理工程イメージ図（滋賀県）




図3 教師画像データからのクラス識別器作成イメージ図

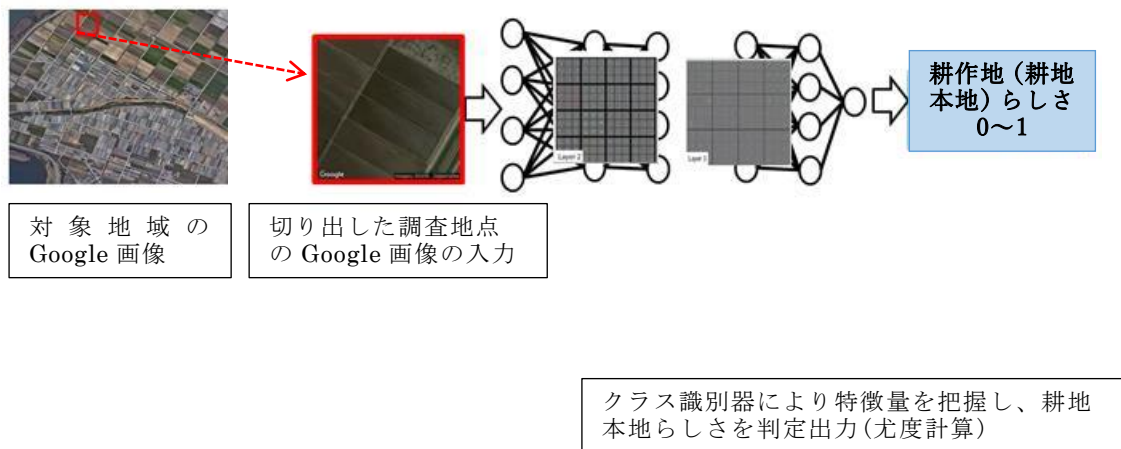


図4 クラス識別器による耕地本地らしさの判定イメージ図

表 1 深層学習法による耕地本地面積率の推計結果

調査対象地域	設計標本規模（設計調査地点数）	深層学習法（%）	ドット標本調査法（%）	農水省公表値 2016年（%）	〈参考〉深層学習法で計算された尤度の平均値	標準誤差（ドット標本調査法）	ドット標本調査法との差	農水省公表値との差
1. 全国（全国一本推計）	1,000	11.5	11.7	11.5	11.9	1.0	-0.2	0
2. 全国（都道府県別推計）	4,700	11.1	11.3	11.5	11.2	0.5	-0.2	-0.4
3. 東北地域	1,000	14.8	12.2	12.1	15.1	1.0	2.6	2.7
4. 北陸地域	1,000	14.2	11.6	11.9	14.6	1.0	2.6	2.3
5. 近畿地域	1,000	8.3	6.8	7.7	8.3	0.8	1.5	0.6
6. 茨城県	1,000	22.6	27.5	27.4	22.6	1.4	-4.9	-4.8
7. 栃木県	1,000	16.8	19.9	18.9	17.2	1.3	-3.1	-2.1
8. 群馬県	1,000	13	9.4	10.8	13.4	0.9	3.6	2.2
9. 埼玉県	1,000	19.3	17.9	19.6	19.2	1.2	1.4	-0.3
10. 千葉県	1,000	19.6	21.9	19.9	19.7	1.3	-2.3	-0.3
調査対象地域の単純平均値	13,700	15.1	15.0	15.1	15.3	0.3	0.1	0.0

出所：表中、農林水産省の公表値は、「耕地および作付面積統計」2016年から引用したものであり、それ以外の数値は推計結果により筆者作成。

注 1) 耕地本地率とは、耕地本地面積を総土地面積で除して求めた値である。これは、深層学習法では畦畔面積の判定を行わなかったため、本来の耕地率（畦畔面積を含む耕地面積の割合）の代替指標として用いたものである。

2) 農林水産省の調査結果は、全国の土地に 200m×200m のメッシュフレームを配置し、耕地のある標本単位区（約 3 万 9000 単位区）での現地調査結果を比推定法で推計した耕地本地面積から計算したものである。重厚な手法であり、我が国の統計の中では最も信頼性のある統計として評価されている。なお、ここで比較年として 2016 年の公表値を用いたのは、比較に用いるドット標本調査が Google Earth の画像を用いており、その取得画像の時期について全国の 50 地点を系統抽出して調査した結果、その時期が平均的には 2016 年と推計されたためである。

3) ここでのドット標本調査法は、Google Earth 上の調査対象地域内に定めた標本調査地点を格子状に配置し、標本地点での土地状況について耕地本地か非耕地かを目視判定し、耕地本地の出現率を推計するものである。格子状の点は、緯度と経度の組合せであるが、東西方向、南北方向とも等距離になるように配置したものである。国際協力の分野では簡便な土地面積調査手法として知られているが、国内での知名度は低いと思われる。なお、本分析では、耕地本地であるか否かは、Google Earth 上の画像から判断しただけであって、現地調査で確認したものではないという限界があると認識している。

表2 深層学習法による尤度値の分布状況（全国）

区分	尤度	ドット標本地点における目視調査結果				有効標本規模 (有効調査地点数)	
		非耕地	本地	畦畔	耕作放棄など		
深層学習法による結果	深層学習法による尤度値が0.5以下	0～0.1	771	45	6	5	827
		0.1～0.2	7	5	0	0	12
		0.2～0.3	9	2	0	0	11
		0.3～0.4	6	5	0	0	11
		0.4～0.5	7	2	0	0	9
	深層学習法による尤度値が0.5より大きい	0.5～0.6	3	2	0	1	6
		0.6～0.7	2	3	1	0	6
		0.7～0.8	9	0	0	1	10
		0.8～0.9	3	4	0	0	7
		0.9～1	33	47	1	3	84
有効標本規模（有効調査地点数）		850	115	8	10	983	

出所：表中の数値は、推計結果により筆者作成。

表3 深層学習法による判定結果とドット標本調査法による目視判定結果のコンフュージョンマトリックス

区分	尤度	ドット標本地点における目視調査結果				有効調査地点数	有効調査地点数の比率 (%)	深層学習結果からみた目視調査の一致率 (%)
		非耕地	本地	畦畔	耕作放棄など			
深層学習法による判定結果	0.5以下非耕地	800	59	6	5	870	88.5	92.0
	0.5より大きな耕地本地	50	56	2	5	113	11.5	49.6
有効調査地点数		850	115	8	10	983	100	87.1
有効調査地点数の比率 (%)		86.5	11.7	0.8	1.0	100.0		
目視調査結果からみた深層学習法の一致率 (%)		94.1	48.7	87.1		87.1

出所：表と同じ。

注：設計標本規模が1,000であったのに対して、有効標本規模はこれより17少ない983となっている主な原因は、北方4島分の調査地点（約14地点分）を調査対象外として集計したためである。残り3地点は標本配置の際に生じる偶然の誤差分であると考えている。



図5 明らかに耕地本地なのに非耕地と判定された画像事例



図6 明らかに非耕地なのに耕地本地と判定された画像事例

表 4 土地利用調査に関する関連研究調査結果との比較

	精度 (G Tデータ との 一致率%)	調査目的	土地利用 区分数	調査対象地域	調査対象規 模 (調査地 点数)	調査地点の 選定方法	調査時期	推計結果 と公的統 計値との 比較検討
JAXA	81.6	土地被覆 図作成	10分類	日本全域	2,922	ランダム サンプリング 地点ではない	2016年	なし
株式会社 パスコ	82.8	土地被覆 図作成	4分類	東京都周辺	60,000	不明(ランダム サンプリング ではなさそう)	2016年	なし
				静岡県周辺				
				福岡県周辺				
京都大学 メディア センター	87.1	土地利用 統計	2分類	日本全土 (北 方4島除く)	983	ランダム サンプリング/ 系統抽出法 設計調査地点数 1000	2018年	あり
	87.7	土地利用 統計	2分類	日本全土 (北 方4島除く) 47都道府県別	4,670	ランダム サンプリング/ 系統抽出法 設計調査地点数 各県とも100	2018年	あり

資料：JAXA 「高解像度土地利用土地被覆図」

(http://www.eorc.jaxa.jp/ALOS/lulc/lulc_jindex_v1803.htm)

株式会社パスコ「ディープラーニングを適用した衛星画像からの土地被覆分類手法の評価」より筆者作成。

要旨

本稿は、2018年度に実施した「深層学習法による衛星画像認識技術を活用した土地利用面積の推計」に関する研究調査結果を取りまとめたものである。本研究調査では、まず、当面の課題となっていた Google Earth 画像を利用したドット標本調査法の準備調査段階の作業として手作業で実施している判読作業の効率化を図るために深層学習による衛星画像判定システム「畳み込みニューラルネットワークによるクラス識別器」を構築し、次いでこの構築したシステムの有効性を確認するため、日本全国から 10 の調査対象地域として指定した調査地点の土地属性を正しく判定し、各対象地域における耕地本地面積を正確に推定できるか否かの試行調査を行った。試行調査の結果は、いずれの調査対象地域においてもドット標本調査による推計値及び農林水産省の公式統計値に極めて近似し、信頼できる推計値であることが確認できた。更に、各標本調査地点における本深層学習法による判定結果とドット標本調査による目視調査結果との一致率は、87%であった。しかしながら、方法論的にみると、ドット標本調査法における目視判定方法が「指定した点地点における属性判定」であるのに対して、構築したシステムでは「指定した点地点を中心とする一定の大きさを持つ範囲における属性判定」にならざるを得ないという限界があること等から、当初の目的としたドット標本調査における準備調査を支援する手法としては限界があることを明らかにした。その上で、本研究が採用した画像からのクラス識別手法に対して、深層学習を用いた画像の領域分割（セマンティックセグメンテーション）も有効であると考えられることを、深層学習による判別手法の今後の課題として指摘した。