

産官学共同研究によるAIを活用した 航空写真画像診断に基づく 現況地目調査の効率化への取組みと 今後の利活用



日本土地評価システム株式会社 システム開発部グループ長 島崎 寛和 氏
名古屋大学大学院情報学研究科安田・遠藤研究室 鵜飼 凌央 氏

産官学共同研究によるAIを活用した航空写真画像診断に基づく 現況地目調査の効率化への取組みと今後の利活用

鵜飼 凌央¹，島崎 寛和²，遠藤 守¹，浦田 真由¹，安田 孝美¹，木村 智行²

¹名古屋大学大学院 情報学研究科 Graduate School of Information Science, Nagoya University

²日本土地評価システム株式会社 システム開発部 System Development Department,
Japan Appraisal System INC.

要旨…地目，つまり土地の用途は日本の土地に対する固定資産税を決定する重要な要素の一つである。地目の判定は各自治体の税務課が行っており，その業務は莫大なコストと労力がかかっている。そこで本研究では，AI技術の一種であるディープラーニングを用いて，航空写真画像から地目の自動判定を試みた。この技術を用いれば自治体がこの業務に割いているコストを抑えることができる。その判定結果を本年度の現況地目調査において利用し，さらに調査結果との比較も行った。また，AIの判定と家屋情報を複合的に利用し判定精度の向上を試みた。本実験において，現況調査を行う上でこのシステムを利用する具体的な方向性を見出すことができた。また，自治体の保有するビッグデータ活用の一例を示すことができた。

キーワード ディープラーニング，機械学習，地目，航空写真，ビッグデータ

1 はじめに

1.1 土地評価の現状

日本の市町村において，固定資産税はとても重要な財源となっている。図1に示した平成27年度の市町村税の内訳を見てみると，固定資産税は8兆7,550億円と全体の41.5%にも登っている。平成29年版地方財政白書¹⁾(総務省)においても，「社会保障や地方創生等，今後ますます増大する市町村の財政需要を支えるため，固定資産税の安定的な確保が重要」(p.資193)であると述べられている。その固定資産税の約38%を占めるのが土地への課税である。

土地への課税は地番という一筆の土地ごとに登記所が付する番号で管理されている。一筆とは登記簿上で一つの土地とされている，土地を数える単位である。その地番ごとに宅地，公衆用道路，一般田などの地目と呼ばれる土地の用途が定められている。地目には登記地目と課税地目の二種類があり，登記地目とは登記簿に記載されている地目のことで，土地の所有者が自ら申請を行う。土地の利用方法が変わったとしても，法務局が地目を変更することはないので，所有者が地目変更登記を行わなくてはならない。一方，課税地目は市町村が調査を行い，土地の用途が変わっていると判断した場合，申請なしで市町村が地目を変更する。各市町村はこの課税地目に従い固定資産税を決定するのである。当然，課税額は地目によって違っており，一定面積当たりの額が100倍違うこともある。よって課税地目の調査は，上述の総務省の見解も合わせて考えると，重要な税務であると位置づけられる。

固定資産の評価にあたっては，訓示規定とされてはいるものの，地方税法第408条において，固定資産の状況を毎年少なくとも一回実地に調査すべき旨が定められている。




図1. 市町村税収入額の状況¹⁾

しかしながら課税地目の調査の現状は、主に人間が現地へ赴き地目を判定しており、とても大きな手間がかかっていると同時に、中規模の一市町村でも土地は何万筆もあり、それら全ての地目を調査するには莫大なコストと労力がかかってしまう。実際に、本研究のフィールドとして協力いただいている半田市税務課では、職員8名で市内の約11万筆を調査する必要があり、毎年全ての筆を綿密に調査するために大変な困難を伴っている。

1.2 官民データ活用推進基本法

近年、ハード、ソフト両面の技術進歩を背景として、社会が蓄積するデータ総量が爆発的に増加している。ここにAI技術の進歩も相まって、データ活用がますます重要視されている。国はこういったデータ活用の活発化の流れを受け、平成28年12月に官民データ活用推進基本法を施行した。この官民データ活用推進基本法の目的は第1条に以下のように定義されている。

インターネットその他の高度情報通信ネットワークを通じて流通する多様かつ大量の情報を活用することにより、急速な少子高齢化の進展への対応等の我が国が直面する課題の解決に資する環境をより一層整備することが重要であることに鑑み、官民データの適正かつ効果的な活用（「官民データ活用」という。）の推進に関し、基本理念を定め、国等の責務を明らかにし、並びに官民データ活用推進基本計画の策定その他施策の基本となる事項を定めるとともに、官民データ活用推進戦略会議を設置することにより、官民データ活用の推進に関する施策を総合的かつ効果的に推進し、もって国民が安全で安心して暮らせる社会及び快適な生活環境の実現に寄与する²⁾。

本研究ではこの官民データ活用推進基本法にのっとりビッグデータ活用の意義を示すことも一つの目的としている。

1.3 先行事例

近年、上述のようなデータ活用やAI利用の機運の高まりを受けて、広域の土地に対する課題を情報技術を用いて解決しようという研究が、試みられるようになってきた。

AI技術の発達、特に近年の機械学習分野での技術革新は、画像や地図情報などの不動産と親和性の高いデータ形式に対して、大きな成果を生み出す可能性がある。S.N.K Amitらによる研究³⁾では空中カメラからの画像を機械学習により画像セグメンテーション、つまりピクセル単位でラベル付けを行い、新旧の空中写真の差異を高い精度で抽出している。この技術はGoogleマップなどの巨大な地図データの更新を、迅速なものにすることが期待できると著者らは述べている。また、建物の変化を抽出できるので、不動産関連の業務にも利用できると考えられる。しかし、上で述べたような地目の判定というタスクにおいては、建物だけでなく農地や道路の変化も考慮に入れる必要がある。よって本研究では画像全体から直接的に地目を判定させるアプローチを取ることとする。




図 2. S.N.K. Amit ら「時系列空中カメラ映像のセマンティックセグメンテーションと差分抽出およびその応用³⁾」

赤：新しい建物
青：建物が消失
緑：他の変化（屋根が変化、再建築）

1.4 目的

本研究の目的は、AI技術の一種であるディープラーニングを用いて、航空写真画像から地目の

判定を自動で行い、その判定結果を実際の現況地目調査に利用することにより、自治体視点、ビジネス視点両面からの今後の活用方針の検討を行うことである。また、この手法は航空写真、地番図のシェープファイル、課税地目データを利用することにより、自治体の保有するビッグデータの活用としての意義もあると考える。

2 機械学習

2.1 ディープラーニング

ディープラーニング（深層学習）とは、機械学習の一手法で、多層の人工ニューラルネットワーク（以下ディープネット）を用いて学習を行う。ディープラーニングの最も大きな特徴は従来の学習とは違い、特徴まで自動で学習を行う点である。サポートベクターマシンに代表されるように、特徴量から分類を行うプロセスは1990年代に既に一定の成果を達成していた⁵⁾。しかし、特徴抽出の処理は人間が手で設計しており、このプロセスが長年の機械学習研究の壁となっていたのである。

ディープラーニングは1980年代には既に知られていたが、ディープネットが過学習を起こしてしまうため大きな成果はあげられていなかった。過学習とは、訓練誤差は小さくできるが、汎化誤差が小さくできない現象である。つまり、学習に用いたデータに対しては精度が高くなるが、それとは別の新しいデータに対しては精度が上がらない、ということである。また、**Gradient Vanishing**（勾配消滅）問題と呼ばれる、層を何度も介すうちに特徴量を示す勾配がなくなってしまう問題があった。これらの問題があったため、1990年代半ばからディープラーニング研究は下火となっていたが、2006年に発表されたHintonらの研究⁶⁾⁷⁾により、それらの問題は解決され、ディープラーニング研究は昨今の隆盛を見せている。

ディープラーニングが高い効果を発揮するには学習データ量が豊富に必要である。本研究のように何万単位のデータがある場合は適した方法論だと言える。

2.2 畳み込みネットワーク

畳み込みネットワーク（Convolutional Neural Network）とは、畳み込み層とプーリング層を交互に積み重ねたディープネットである⁸⁾。特に、画像データの学習において、1ドットずつではなく、一定領域をもつフィルタを用いて特徴抽出を行う方が画像の移動や変形などに強くなり、また、境界などの領域ベースでないわからない特徴抽出も可能になる。このフィルタをかけ新たなレイヤを生成する層を畳み込み層（図3のC）と呼ぶ。その層から、活性化関数と呼ばれる入力信号の総和がどのように活性化するかを決定づける、つまり次の層に渡す値を整える関数を介し、プーリング層（図3のP）は後の層で扱いやすくするため、画像サイズの圧縮を行う。その繰り返すにより得られた特徴量から、全結合層（図3のF）にて分類を行う。この畳み込みネットワークは過学習を起こしにくく、特に画像認識において良好な性能を示している。本研究で利用したGoogleNetというネットワーク

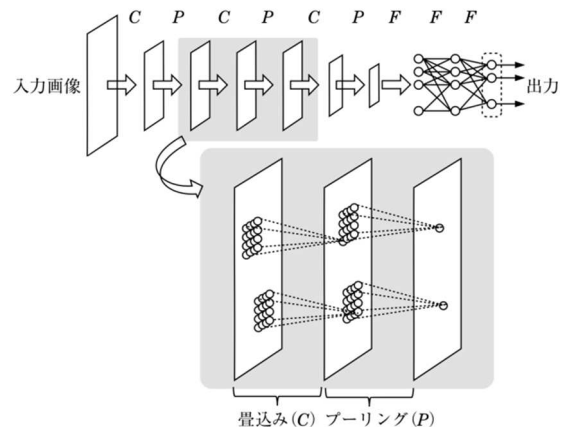


図 3. 畳み込みネットワーク⁵⁾



図 4. GoogleNet⁹⁾

もこの畳み込みネットワークを利用している。GoogleNet (図4) はGoogleが開発したネットワークで、22層のレイヤーを持ち複数のCNNを並列に並べているのが特徴である。CNNのサイズやパラメータ数を抑える代わりに層をより深くした構造を持っている。

3 データ

3.1 航空写真

本研究では学習データとして平成 26 年に撮影された愛知県半田市の航空写真, および平成 30 年に撮影された愛西市の航空写真を利用した。また、今年度の地目判定を行う対象となる画像として、平成 29 年 10 月に撮影された半田市航空写真を利用した。図 5 に示すように元データの形式はどれも .jpg ですがすべてのファイルに対して座標情報があり、これを後述するシェープファイルとの位置合わせに利用した。半田市は地目として宅地が多く農地が少なかったため、不足データを補うため農地の多い愛西市にもデータを提供していただいた。



図 5. 半田市航空写真

3.2 地番図シェープファイル

本研究では地番ごとに区切られたシェープファイルを利用した。シェープファイルとは米 ESRI 社の開発した GIS (Geographic Information System : 地理情報システム) データフォーマットの一つである。 .shp, .dbf, .shx という 3 つのファイルから構成されており、それらは空間情報と属性情報を持つ⁴⁾。シェープファイルにおいて一つの閉じたポリゴンのことをフィーチャーと呼ぶ。本研究で用いる半田市および愛西市全域の地番図シェープファイルは、図 6 のようにフィーチャーごとに Number という一意に定められた数字が属性情報として格納されており、これらは地目データと紐付けられている。Number は半田市シェープファイルに約 11 万、愛西市シェープファイルに約 12.5 万あり、これはすなわちそれぞれの市にその数の地番があることを示している。




図 6. 半田市シェープファイル

3.3 課税地目データ

本研究ではシェープファイルの各フィーチャーに紐付けられた課税地目データを利用した。元データの形式は .xlsx で上述の Number 一つ一つに対し、その地目が記録されている。このデータには約 30 種類の地目が存在した。これらの地目がディープラーニングのモデル学習時のラベルとなる。

4 地目判定モデルの生成

4.1 データセットの準備

本研究では、航空写真画像をシェープファイルの各フィーチャーごとに切り出し、それに地目のラベル付けを行うことでデータセットとした。全ての処理は Python 3 でプログラムを組み自動化した。画像は位置情報を持つ GeoTIFF 形式でも出力でき、一つ一つを GIS ソフトに読み込むことが可能である。

4.2 学習

本研究では NVIDIA DIGITS という GUI ベースでディープラーニングによる学習を行えるシステムを用いた。表 1 に学習条件を示す。今回の調査は半田市の市街化区域における主に農地の調査であったため、それに合わせて設定した。具体的には、ラベルは一般畑、一般田、宅地、雑種地、その他の 5 種類、トレーニングに利用した画像は各ラベル 20,000 枚、バリデーション（モデルが特徴を学習できているか確かめるために行う各エポック毎のテスト）に利用したのは各 5,000 枚である。これら 25,000 枚の画像は各ラベルのデータの中からランダムに抽出したものである。

また、この条件で行った学習の学習曲線を図 7 に示す。loss(val)が単調減少していることから、比較的良好な学習となっていると考えられる。この得られたモデルを利用して今年度の地目の判定を行う。

表 1. 学習条件

Labels	一般畑, 一般田, 宅地, 雑種地, その他
Training Images	各 20,000
Validation Images	各 5,000
Model	Caffe
Networks	GoogleNet
Epoch	30




図 7. 学習曲線

4.3 学習の評価

機械学習の精度評価の指標はいくつかあるが、今回の場合、多クラス分類であること、またニューラルネットを用いており出力が「そのクラスに属する確率」で記述されるという点を考慮し、本研究ではラベル毎の Accuracy および Logarithm Loss を用いることとする。ラベル毎の Accuracy は、以下で表される。

$$accuracy = \frac{T}{P}$$

P : あるラベル A のデータ数

T : あるラベル A のデータのうち機械が A と判定した数

これは、端的にラベル毎の正答率を表している。

また、Logarithm Loss は以下で表される。

$$\text{logloss} = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^L y_{ij} \log p_{ij}$$

N : データの数, L : ラベルの数

p_{ij} : i 番目のデータがクラス j に属する確率

y_{ij} : i 番目のデータがラベル j に属するか否か (属していれば1, 属していなければ0)

p_{ij} はいわゆる分類器の自信のようなもので、この値が高いほど自信を持って判定をしているということになる。そしてその判定が正しかった場合、Logarithm Loss は小さくなる。つまり Logarithm Loss が0に近いほど、良い分類器であると言える。実際に今回のバリデーションに用いた各ラベル5,000枚の画像に対してこれら二つの値を計算した。その結果を表3に示す。

表2. ラベル毎の Accuracy と Logarithm Loss

Accuracy					Average Accuracy	Logarithm Loss
一般畑	一般田	宅地	雑種地	その他		
33.74	83.88	59.42	48.28	51.46	55.36	0.4711

この程度の精度であることを念頭に置きながら以下の実験を行っていく。

5 実験および結果と考察

5.1 【実験1】半田市現況調査での利用

5.1.1 現況調査

2018年8月8日に半田市の現況地目調査に同行し、本システムの利用方法の検討を行った。事前に平成29年10月撮影の半田市航空写真から前述のモデルで地目の判定を行っておき、その結果をリストの形で出力したものを持参した。図8はその一部である。リストには Number や地目の判定だけでなく、所在地やそれぞれの地目の判定の確度も合わせて出力した。

図8. 地目の判定結果リスト

今回の調査の対象は主に市街化区域の農地であり、前年度の課税地目と比較し、農地から宅地、またその逆の変化が見られた土地を重点的にいくつか周った。また、判定の確度が低い数値となっている土地も確認し、どういった土地の要素が判定に迷いを生じさせているのかといった点も意識しつつ現地を周った。以下に調査の様子をまとめる。

(1) 土地 A

昨年のデータ：一般畑

AI の判定結果：一般畑 86%，一般田 13%，宅地 1%
調査での結果：一般畑

AI は一般畑と正しく、しかも 86%という高い確度で判定していた。このように比較的緑があり、土も見えている土地は AI が一般畑と自信を持って判定する傾向が見られた。

**(2) 土地 B**

昨年のデータ：一般畑

AI の判定結果：その他 47%，一般田 36%，宅地 14%
調査での結果：一般畑

AI はその他という判定をし、迷っている印象を受けた。この土地は、ほぼ土が露出しており一見雑種地であるが、果樹が3本だけ植えられており、判断によっては一般畑ということになる。これは人間が目で見なければ判断できない土地であり、現状 AI に判定させるのは難しい土地である。こういった土地が少なからず存在することを現地を周って痛感した。

**(3) 土地 C**

昨年のデータ：雑種地

AI の判定結果：一般畑 77%，宅地 11%，一般田 8%
調査での結果：宅地

昨年まで駐車場として利用していた土地であったが、今年建物が建てられていた。航空写真の撮影タイミングにより判定できないケースとなった。こういった航空写真の撮影日と現況調査日の時期の差によって生じてしまう問題については、今後、衛星写真の利用による解決を検討している。

**(4) 土地 D**

昨年のデータ：宅地

AI の判定結果：一般畑 89%，宅地 7%，一般田 3%
調査での結果：宅地

前年度の課税地目が宅地である土地を AI が高い確度で一般畑と判定していたため確認した。しかし、家が建っており完全な宅地だった。この土地の場合、庭に緑が多いことや、屋根の色も影響しているのではないかと考えられる。このように AI が大きく間違った判定をしている土地もあり、その点は改善が必要である。改善方法の一つとして、AI の判定と、その他のデータによる判定を複合的に利用する方法が挙げられる。このアプローチについては【実験 2】で試みた。



5.1.2 考察およびフィードバック

まず、AIが一定の精度を持って判定が行えていた点は評価できる。その上、実際に地目を変更する必要のある土地を発見することができたことは今後の本システムの利用方法を検討していく上で、非常に意義があることであった。しかし、今回の実験において、本システムが目指している利用方法が完全に実践されたとは言えない。本システムは全ての地目を完璧に判定することを目指しているわけではなく、調査を行う上で、優先順位をつける判断材料の一つとして利用することを想定している。そういった意味では事前にAIの判定結果から現況調査のルートを作成する等、コストカットを狙った利用方法を実践することが重要である。この点は今後、実践していきたい。

今回の調査では、AIのシステムと同時にリモートセンシングにより収集した植生情報も一つの判断材料として現地を周っていた。リモートセンシングは植物から発せられる赤外線情報を蓄積しており、植物の種類まで把握することができる。よって植物の有無や、田畑と雑種地の区別を行う際に、一定の効果が期待できる。しかし、対象が植物のみに限られることや、季節によって植生が異なってしまうことなどは問題点として挙げられる。より良い判定精度を効率よく実現していくためには、AIとは別にこういった他のデータも含めた複合的な判断を行うことが重要になってくることを実感することができ、今後の方針を固めることができた。また、本システムを利用した調査を終えて、半田市税務課様と日本土地評価システム様からフィードバックをいただいた。

(1) 半田市税務課様

- ・RGBの結果だけでは情報が不足しているため建物ポリゴンをはじめとしたその他の情報を総合的に判断させる仕組みが必要である。
- ・アプリケーションとして提供していくことを想定すると航空写真のようにデータ容量の大きな情報を扱うためスペックの高いPCが必要である。
- ・AIでの判読作業においても、スペックの高いPCが必要である。
- ・農地とすべきか否かの判断をする際に、AIが出してきたデータに対ししきい値を設けることになるが、どこでラインを引くかは更なる検討が必要である。
- ・複数種類のデータを取り込んだ場合、AIの性質上何をどう判断したかが見えないので、データを扱う職員にもそれなりのAIに関する知識が必要である。
- ・一般的なイメージとして、AIは便利そうだが本当に効果が出るのかわからない、だから導入できないという声は一定数存在すると思われるので、精度が必要である。そのためには、多くの市町から情報を提供してもらい、AIの学習をより進める必要がある。

(2) 日本土地評価システム様

【良かった点】

- ・実際にAIが判定した結果が正しく、課税地目の見直しが必要な筆の抽出が出来た。
- ・リモートセンシングと比較した結果、それぞれの手法について利点と課題点が判明し、両者の利点を組み合わせることにより、精度向上が期待できる。
- ・AIが迷った箇所を実査にて確認することにより、AIの判定確度の検証と課題が見つげられた。

【問題点】

- ・注意箇所の洗い出し→現地調査→結果整理までの効率的なワークフローが必要。
- ・航空写真からの判断結果だけでは、十分な有益性がないため、他のデータとの組み合わせや結果の活用方法を更に検討する必要がある。
- ・自治体が作成する航空写真は撮影条件に差異があり（時期、撮影間隔、撮影条件等）、データの前処理や画像の精度に課題が残る。

【今後に向けて】

- ・自治体が持っている既存情報やオープンデータとの組み合わせにより、判定精度のより一層の

向上を図る。

- ・自社の現地調査システムと連携させることにより、自治体の現地調査のための準備作業及び後処理作業について大幅な効率化を実現する。
- ・航空写真だけでなく衛星写真も活用することで撮影条件のバラツキを少なくする。

5.2 【実験2】建物情報とAIの複合的判定

5.2.1 実験条件

【実験1】で述べたように効率よく地目の判定精度を向上させていくには、AIでの判定結果以外の情報も複合的に利用し、最終的な判定を行っていくことが重要である。本実験では、その一例として建物情報を利用する。日本土地評価システム様を通じて半田市様からご提供いただいた建物のシェープデータの中から、土地全体の面積に占める建物割合が5%以上のものは宅地である可能性が高いとして、AIの判定とは別階層での判断を行う。また、AIが宅地と判定したもので建物割合が0の場合はAIの結果が疑わしい可能性が高いと言える。よって図9のような条件で判定を行った。ここでのPは以下の式で表される。その判定結果を用いて【実験1】の土地Dのような土地について正しく判定できているか、考察する。

$$P [\%] = \frac{\text{建物の面積}}{\text{土地の面積}} \times 100$$

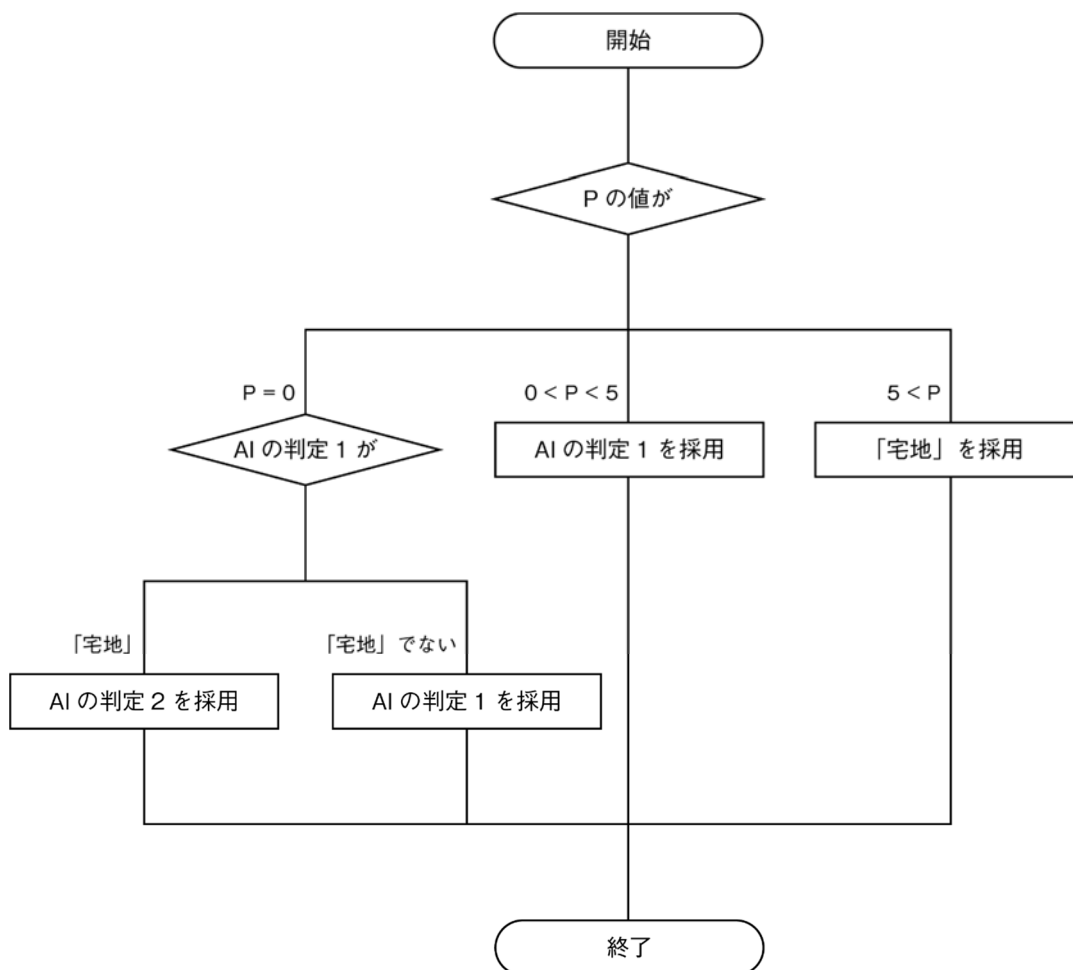


図 9. 地目判定フローチャート

5.2.2 結果と考察

【実験1】の土地Dに対する判定は「宅地」となり、AIの判定結果の誤りを正すことができた。また、その他にも同様な土地で一定の効果を示した。しかし一部で、AIが宅地であると正しく判定していたのにも関わらず、判定結果が違う地目へと変わってしまった土地もあった。これは最新の修正後の建物のシェープデータがまだ入手できなかったため、今回の実験に用いた建物のシェープデータは航空写真の撮影時期と年度が異なり、差異が生じているためである。

このように、既存の土地情報を利用した判定も、利用するデータの各々の作成時期が不一致であるとAIの判定同様完璧ではないことが分かる。よって、利用する各データ特性を理解した上でその強みをバランスよく取り入れることができる閾値の設定や、判定プロセスの構造を決定していくことが、重要である。

5. 結論

本研究ではディープラーニングを用いて航空写真から自動で地目を判定させ、その結果を現況地目調査において利用した。調査では実際に宅地に変わっている土地を発見することができるなど、実践的な面で一定の成果があったが、人間が確認しなくては判断できない土地も多くあり、AIの活用場所をしっかりと見定めていくことが大事であると痛感した。また、判定が合っている土地、誤っている土地を実際に現地で見ただけによって、今後効率よく判定精度を改善していくためには、AIの判定結果とは別に他のデータによる判定を複合的に利用することが重要であることが分かった。その一例として家屋情報を利用することにより宅地の判定精度の向上を試みた。宅地の土地の判定精度向上に一定の効果があつた。他にも、リモートセンシングによって収集された植生情報も複合的に利用していくことも検討している。また、技術的なことだけではなく、自治体の方々に使っていただけるためには、さらに実践的な利用実験を重ねる必要があると実感した。

本年度は航空写真を用いて判定を行ったが、今後人工衛星のオープンな利用が広がれば、衛星画像をデータとして利用することができる。すると、航空写真よりも早く安く、柔軟な地目判定のシステムの実現が期待できる。また、本研究ではデータセットの生成のために、航空写真、地番図シェープファイル、課税地目データを利用しており、自治体の持つビッグデータの利用という面で、一定の意義を示すことができた。

謝辞

各種データを提供していただいた半田市役所及び愛西市役所の関係各位に深謝する。なお、本研究の一部はJSPS 科研費 15K00448, 15K16097 の助成を受けたものである。

参考文献

- 1) 総務省 (2017): 平成 29 年版地方財政白書, http://www.soumu.go.jp/main_content/000472872.pdf (最終閲覧日 2018 年 9 月 4 日) .
- 2) 首相官邸 (2016): 官民データ活用推進基本法の概要, https://www.kantei.go.jp/jp/singi/it2/hourei/pdf/detakatsuyo_gaiyou.pdf (最終閲覧日 2018 年 9 月 4 日) .
- 3) Amit, S. N. K., Saito, S., Sasaki, S., Kiyoki, Y., & Aoki, Y. (2015): Semantic segmentation and difference extraction via time series aerial video camera and its application. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 40(7), pp.1119-1122.
- 4) Zeiler, M. (1999): Modeling our world: the ESRI guide to geodatabase design. ESRI, Inc., p.68.
- 5) 岡谷貴之. (2014): ディープラーニング. 映像情報メディア学会誌, 68(6), pp.466-471.
- 6) Hinton, G. E., Osindero, S., & Teh, Y. W. (2006): A fast learning algorithm for deep belief nets. Neural computation, 18(7), pp.1527-1554.
- 7) Hinton, G. E., & Salakhutdinov, R. R. (2006): Reducing the dimensionality of data with neural networks. science, 313(5786), pp.504-507.
- 8) LeCun, Y., Bengio, Y., & Hinton, G. (2015): Deep learning. Nature, 521(7553), pp.436-444.
- 9) Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015): Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9.