

AIを活用した 地物自動抽出に関する研究

【研究期間】

平成30年4月～令和5年3月

【予算】

特別研究経費 55,758千円(平成30年～令和4年度の総額)

国土地理院 地理地殻活動研究センター
地理情報解析研究室
大野 裕幸

1. 研究の背景と目的

地図作成工程の流れ

写真撮影

標定

図化

地図編集

測量成果

(地図と位置合わせ)

(図化ソフト)



※地理院地図から引用

【課題】

・労働集約型

【背景】

コンピュータの能力向上
AI技術の実用化

研究目的

「図化」の工程のブレークスルーを実現する地物抽出AIの構築

1. 図化とは



空中写真測量における数値図化とは、空中写真及び同時調整等で得られた成果(本研究では「カメラパラメータ」という)を使用し、デジタルステレオ図化機によりステレオモデルを構築し、地形、地物等の座標値を取得し、数値図化データを記録する作業をいう。(準則第311条)

※「地形」は本研究の対象外。



デジタルステレオ図化機でも図化素図の内容は同じ。ただし、2500レベルの図化のため、建物形状はより詳細に図化されるようになっている。



アナログ図化機時代の図化素図。土地利用なども図化機で記号が描画されている。25000レベルの図化素図のため建物の形状は簡略化して図化されている。(国土地理院HPから)

【目標(数値目標)の設定】

①抽出成功率の達成度判定の目標

40項目以上の地物に対し、基盤地図情報の精度の範囲内※1で人が判読した場合に匹敵する抽出成功率の達成
(参考：自動抽出の対象となる地物は93項目※2)

②実用的なレベルへの到達度判定の指標

抽出対象となる地物数全体の**80%程度**の抽出

技術的なブレイクスルーとすることを標榜していることから、非常に高い目標を設定。

※1 基盤地図情報項目以外は、電子国土基本図で必要とされる精度とする

※2 地図情報レベル2500の項目のうち、行政界や建物記号などの、本質的に画像やセンサーで観測できない項目と等高線の分類項目を除外した項目数

(終了時評価時追記:この時点では比高の影響(後述)は考慮されていなかった)

1. 目標達成状況（中間評価時の資料を再掲） 国土地理院

数値目標①

40項目以上の地物に対し、基盤地図情報の精度の範囲内で、F値 ≥ 0.8

達成できているのは

- | | |
|------------------------|----------|
| ・ 道路（2101道路縁、2106庭園路等） | F値 0.807 |
| ・ 水部（5101水涯線、5105湖池） | F値 0.862 |
| ・ 建物（3001普通建物） | F値 0.803 |

➡ **達成率12.5%**

の5項目のみ。

※終了時評価注：スコアの算出方法とF値についてはSlide29～30に記載

主要項目に絞って学習データの効率的な作成方法などの基礎的な検討を優先していたため（これらは目標には反映されない）、達成率は低い。

しかし、現在の研究の流れにおける個別項目のF値向上は第3段階（Slide14）のタスクである。主要項目では目標をクリアし、おおむね計画どおり。

数値目標②

レコード数ベースの抽出率で、80%以上

対象となる電子国土基本図（地図情報）のレコード数は、約1億8097万レコード。

- | | | | |
|--------------------|------------|---|--------|
| ・ 道路（占有率 18.87%） | × F値 0.807 | = | 15.23% |
| ・ 水部（占有率 7.17%） | × F値 0.862 | = | 6.18% |
| ・ 普通建物（占有率 34.54%） | × F値 0.803 | = | 27.74% |

合計値 49.15% ÷ 80.00%

➡ **達成率 61.44%**

中間評価(令和3年3月1日)後の研究環境の変化

- 人事異動により令和3年4月以降研究官が1名減
 ➡ 以後2カ年は本研究の担当研究官が室長1名のみに



- 特に「項目数」の数値目標(40項目)の達成は困難なことから本来の目的である「ブレークスルー」の実現に取り組む



いくつかの地物で、「自動図化」の実現に至った

※「自動図化」は昭和50年代から研究開発が続けられてきた課題。これまで自動図化に成功したことは無かった。

2. 研究の流れ

地図作成工程

本研究では標定は図化工程の一環として行う

写真撮影

~~標定~~

図化

地図編集

測量成果

写真入力※

地物抽出

後処理

標定

図化結果

※オルソ画像ではなく空中写真画像をそのまま入力

②抽出漏れ低減手法



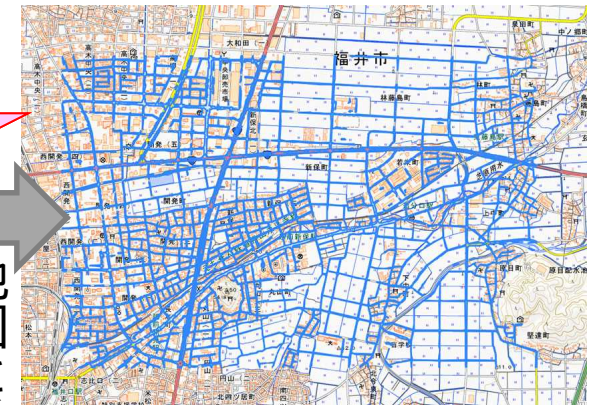
CCB-2021-3-N-C05_0008



道路1960枚モデルで道路を抽出



抽出された画素を取り出す



道路の自動図化結果
(青色の線。地理院地図で表示)
南北コースで撮影されているため、
図化結果は90度向きが変わっている
※背景は地理院地図

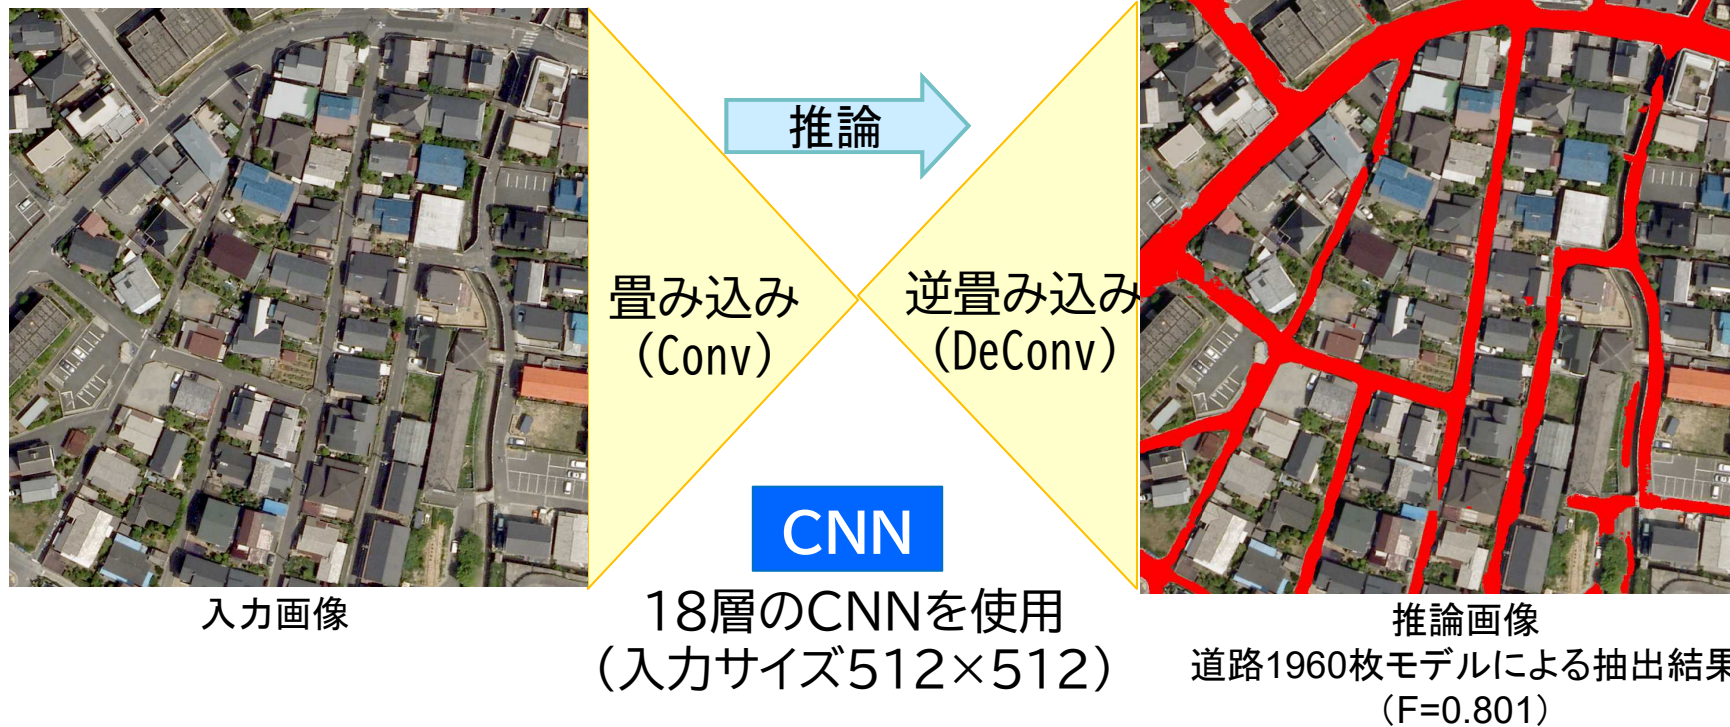
①地物抽出用AIの開発

変換してマージ
地図と重なるよう

※地図と重なるよう変換する際(正射変換)には基盤地図情報の地形データを用いている。地形データの取得は、本研究の対象外である。

3. 地物抽出用AIの開発

※深層学習、推論、F値に関しては、参考資料のスライド27~30を参照



この例では、入力画像の中で道路が映っている画素をAIが識別して赤色に着色している。

学習データの例 (道路)



オリジナル画像 ラベリング画像



オリジナル画像 ラベリング画像

【参考とした研究について】


※本研究で用いたCNNは、Conditional-GAN(Isola et al. 2017)の発生器を出自としているため、対象地物を存在確率として出力するのではなく、対象地物を着色した画像を発生させるという考え方を採っています。そのため、損失関数にはクロスエントロピーではなく、L1距離を使用しています。

3. 地物抽出用AIの開発

- AIの学習は、(最初のモデルを除き)学習済モデルの推論結果から、誤抽出や抽出漏れが生じた箇所を選定し、ラベリングした画像を追加して学習、を繰り返す
- 誤抽出を避けるため、対象地物が含まれないFALSE画像も含める
- 検証用のデータ(デジタル航空カメラで撮影された568地区から機械的に選出)と比較することで抽出性能=スコア※(0~1.000。1に近いほど性能が高い)を算出

※スコアの算出方法とF値についてはSlide29~30に記載


学習データの例
(道路)



オリジナル画像 ラベリング画像(TRUE)



オリジナル画像 ラベリング画像(FALSE)



※学習データは90度、180度、270度に回転させた画像を追加しているため、実際の学習に使用した枚数は、表示枚数の4倍の枚数となる。

3. 地物抽出用AIの開発



入力画像(検証用40番)




普通鉄道


普通鉄道1600枚モデル(F=0.708)



駐車場1700枚モデル(F=0.779)



検証用カテゴリ分類
(カテゴリごとに色分け)



普通建物1200枚モデル(F=0.800)




道路1960枚モデル(F=0.801)


3. 地物抽出用AIの開発(自然植生)



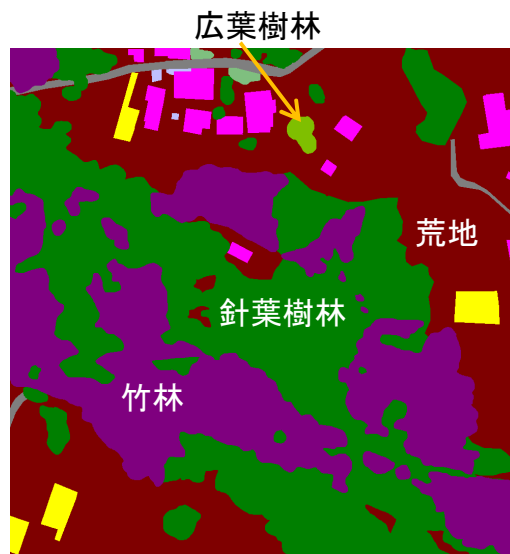
入力画像(検証用261番)




竹林1600枚モデル(F=0.608)



針葉樹林760枚モデル(F=0.679)



検証用カテゴリ分類
(カテゴリごとに色分け)



広葉樹林640枚モデル(F=0.388)



しの地480枚モデル(F=0.339)

3. 項目別の抽出性能(2023-02-16時点)

項目	学習枚数 (現在)	F値 (中間評価時)	F値 (現在)	項目	学習枚数 (現在)	F値 (中間評価時)	F値 (現在)
02・03道路	2000	0.807	0.801	19竹林	1600	-	0.608
04駐車場	1900	0.563	0.779	20針葉樹林	800	-	0.679
05分離帯	2600	0.113	0.619	21茶畑	640	-	0.830
06軌道	2000	0.380	0.712	22果樹園	640	0.053	0.312
07水部	1250	0.862	0.820	26しの地	520	-	0.339
08堅牢建物	1000	0.199	0.415	27メガソーラー	680	0.461	0.844
09普通建物	1200	0.803	0.800	38プラットホーム	2200	-	0.674
10無壁建物	960	0.169	0.688	39タンク	536	-	0.855
13透過水制	920	0.470	0.801	40広葉樹林	640	-	0.400
14横断歩道橋	1700	-	0.557	41風車	640	-	0.513
16畑	1600	0.442	0.445	44防波堤	1340	-	0.815
17水田	2600	0.557	0.780	54芝地	400	-	0.462

※実際のトレーニングに使用する学習枚数は、3方向に回転させたものを加えるため、4倍となる。

※使用するCNNを中間評価時点の16層(入力画像サイズ256x256ピクセル)から18層(同512x512ピクセル)に変更したため、F値が下がっている場合がある。05分離帯と06軌道のみ20層(入力画像サイズ512x512ピクセル)のCNNを使用。中間評価時の学習枚数と比較する場合は本表の数を5倍する必要がある。

※F値の算出には検証用に別途作成したデータセット(1000x1000の画像338枚+572x572の画像230枚を基本。3000x3000の画像を追加した項目も12ある)を使用。19竹林、20針葉樹林、26しの地、40広葉樹林は、1000x1000の画像338枚のみで評価。

※F値(現在)記載の数値は、これまでで得られた最高値であり、学習枚数(現在)のモデルで得られた値とは限らない。

3. 項目別の抽出性能(2023-02-16時点)

項目	学習枚数 (現在)	F値 (中間評価時)	F値 (現在)
58砂礫地	960	0.324	0.324
63高塔	2900	0.111	0.617
68墓地	1700	0.025	0.806
リソース不足による途中断念分			
23荒地	200	0.132	0.253
28輸送管	140	-	-
36雪覆い等	240	-	0.016
43不透過水制	60	-	-
61たたき	80	-	0.039
65湿地	320	-	-
66材料置場	60	-	-
67園庭	80	-	0.178

項目	学習枚数 (現在)	F値 (中間評価時)	F値 (現在)
本研究の手法が適合しないことによる断念分			
11被覆	500	0.029	-
12土がけ	600	0.012	-
34石段	400	-	-
62岩がけ	400	0.021	-
ハイマツ地	0	-	-

※リソース不足による途中断念分は、地物数が少ないもの、特徴量があいまいなもの(例えば雪覆い等は、多くの場合上部が植生に覆われていて雪覆いとしての特徴量を呈しているケースは限られる)、その他分類不能的な要素を含むもの(荒地、たたき)を中心に選定

※本研究の手法が適合しないことによる断念分は、「比高」が関与する地物で、1枚の写真からでは高さに関する特徴量の抽出が不可能であるため、除外したもの。類似の地物に「08堅牢建物」(コンクリート造りでも2階建て以下は09普通建物としなければならない)がある。

※ハイマツ地は、写真に撮影された事例が極めて少なく、学習データ作成の対象時期(2007~2017年)の撮影事例が発見できなかった。

4. 抽出漏れを低減させる後処理手法

地図作成工程

本研究では標定は図化工程の一環として行う

写真撮影

~~標定~~

図化

地図編集

測量成果

写真入力*

地物抽出

後処理

標定

図化結果

※オルソ画像ではなく空中写真画像をそのまま入力

②抽出漏れ低減手法



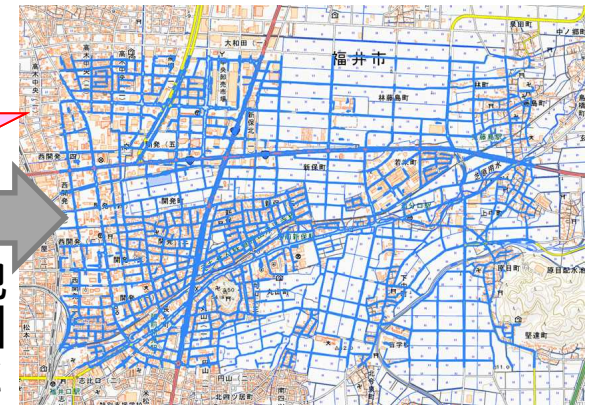
CCB-2021-3-N-C05_0008



道路1960枚モデルで道路を抽出



抽出された画素を取り出す



道路の自動図化結果
(青色の線。地理院地図で表示)
南北コースで撮影されているため、
図化結果は90度向きが変わっている

①地物抽出用AIの開発

地図と重なるよう
変換してマージ

※地図と重なるよう変換する際(正射変換)には基盤地図情報の地形データを用いている。地形データの取得は、本研究の対象外である。

4. 抽出漏れを低減させる後処理手法

■ OR型（一般的な地物用）

- 複数の方向から撮影された画像の抽出結果の論理和(OR)を取るもの
- 再現率より適合率を高め誘導するよう学習データを構築
 - 漏れが生じても良いので、誤抽出をできるだけ少なくするよう育成

実装



正射変換※

正射変換

正射変換

マージ

※1つの画像で抽出漏れの部分が、別の画像の抽出結果によって補完される。

※各画像の誤抽出が多いとマージ後に誤抽出だらけになってしまう。

複数の抽出結果を地図上でマージすることで抽出漏れを軽減できるのでは、という発想

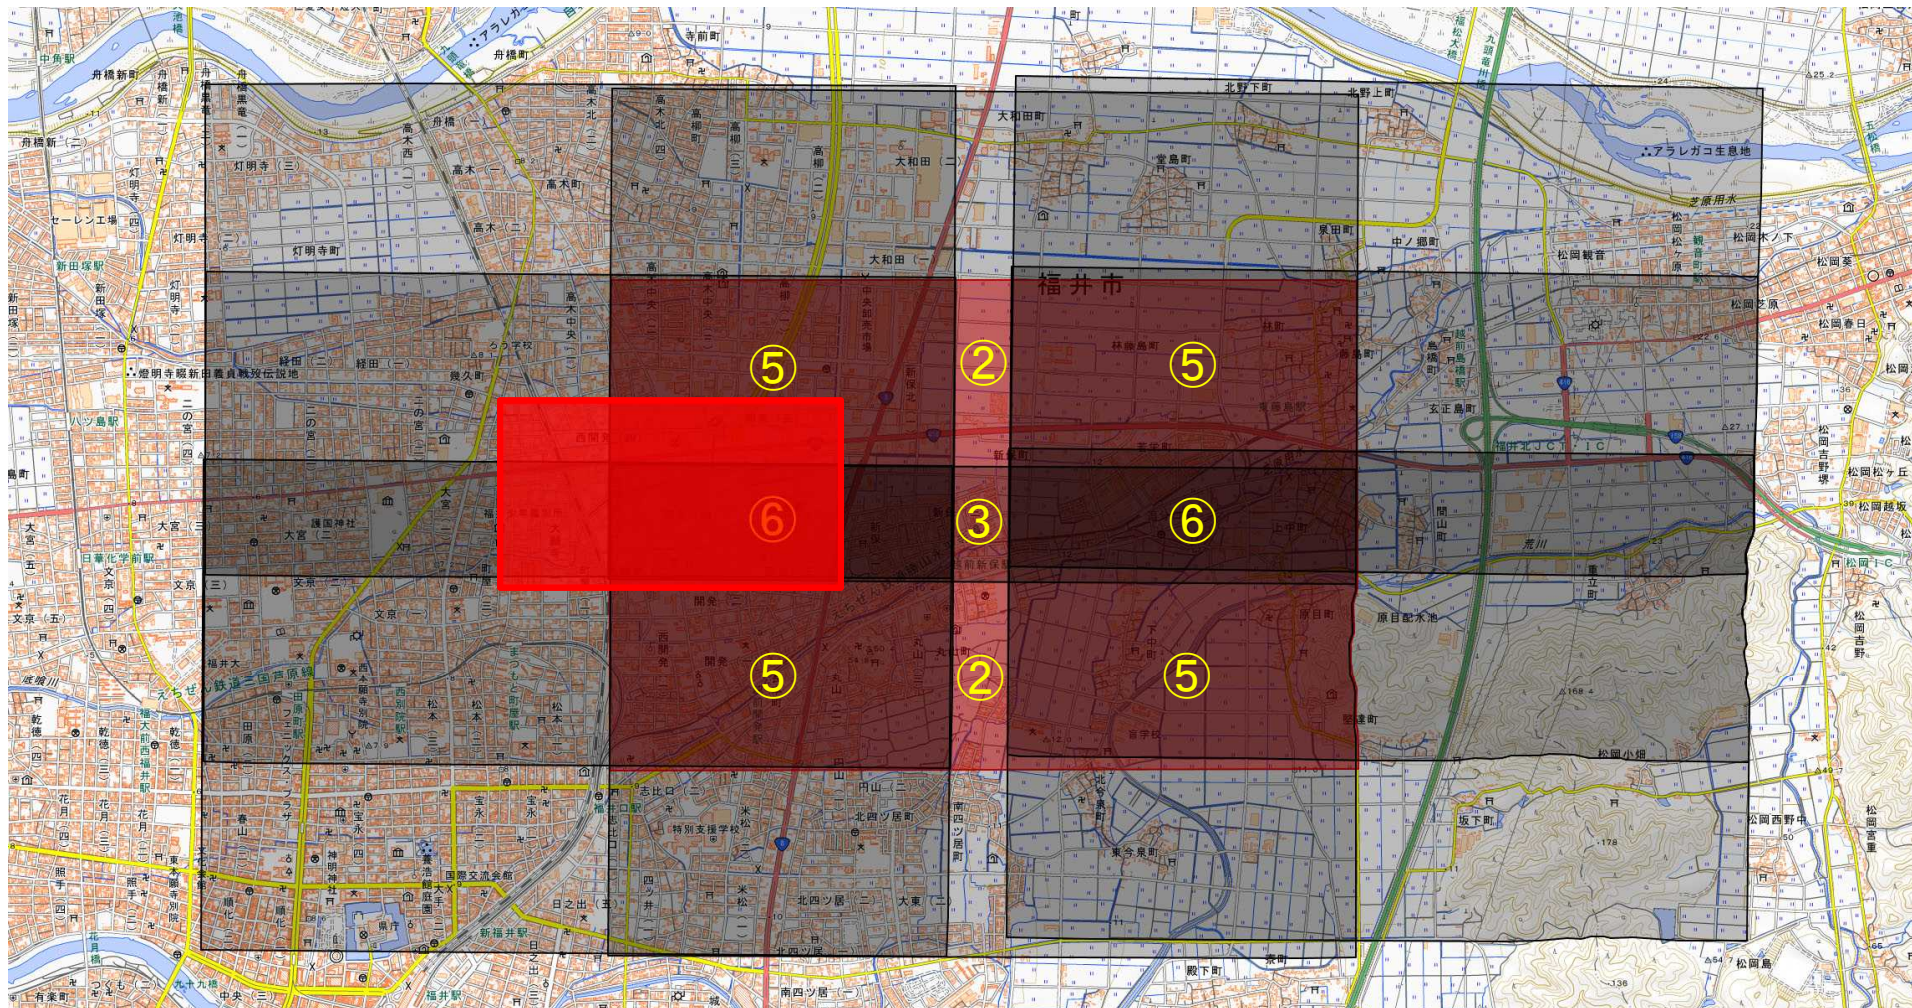
➡ 生の空中写真(とカメラパラメータ)を使うことで可能となった手法

※正射変換とは、写真上で取得された位置を、地形を考慮して歪みを取り地図と重なる位置に座標変換すること。

※本スライドは、中間評価時の資料-3、スライド27を一部修正したものである。

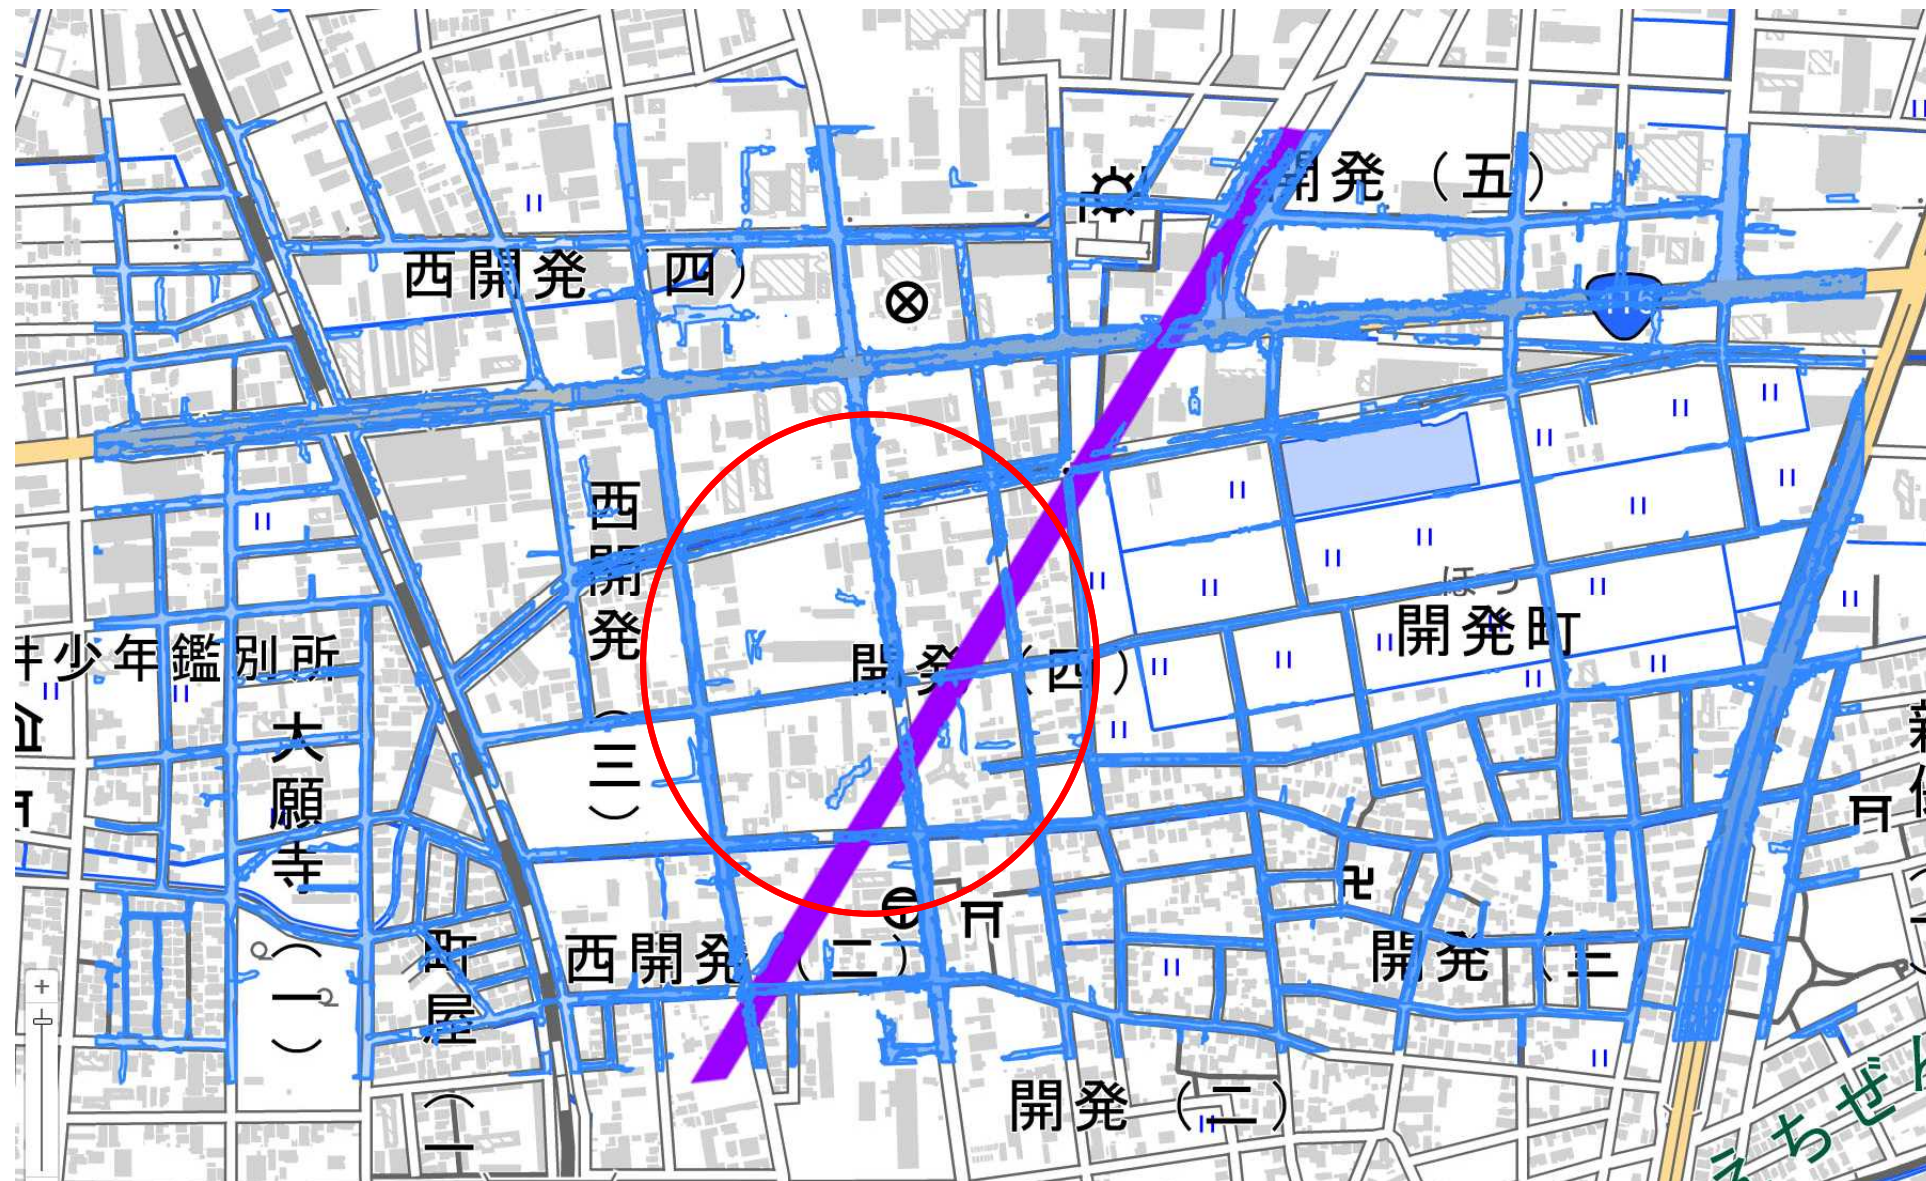
4. 抽出漏れを低減させる後処理手法

※本スライドは、アニメーションを含んでいます。



※実際は、さらに上下に3枚ずつの写真が重複して撮影されているが、分かりやすくする観点から省略している(Slide18まで同じ)。

4. 抽出漏れを低減させる後処理手法



※本スライドは、アニメーションを含んでいます。

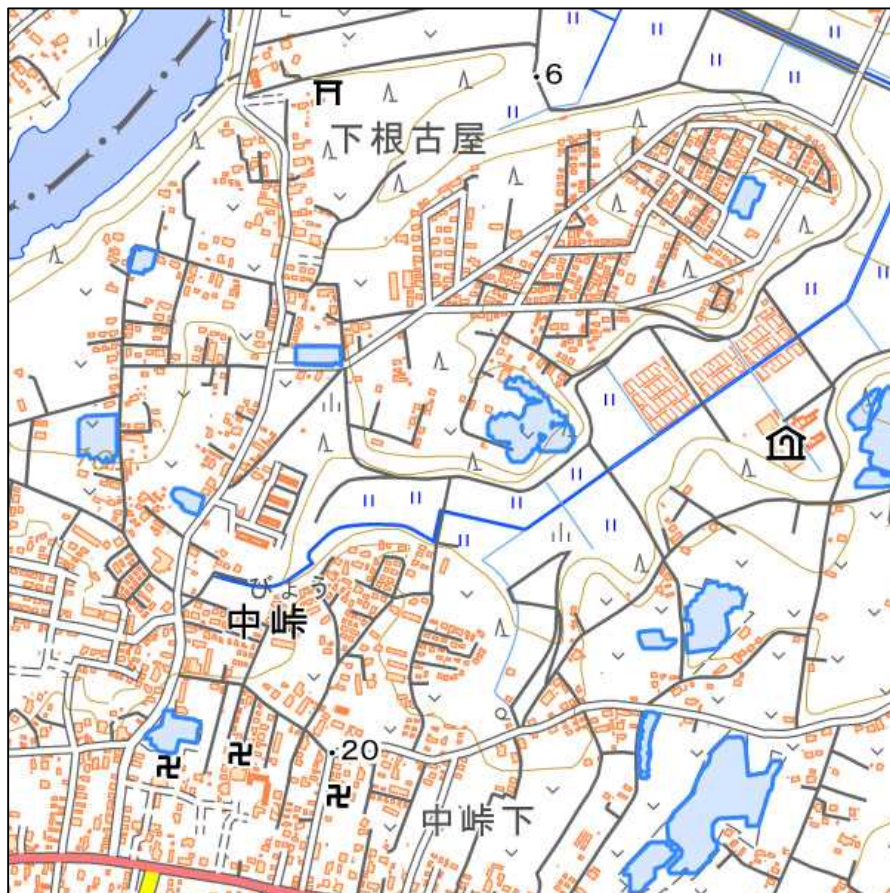
5. 自動図化の実現(道路の例)



1枚の空中写真(CCB-2021-3-N-C05_0008)の範囲を地理院地図上で表示したもの。黒枠が写真の範囲。水色の線が道路の自動図化結果。人間が介在せず得られた図化結果である。

5. 自動図化の実現(メガソーラーの例)


本研究で構築した自動図化機構の使い方は、バッチファイルをダブルクリックするのみ。地物抽出用のAIと後処理設定の番号を差し替えるだけで、対象地物を容易に変更できる。




CKT20193(空中写真1445枚)からメガソーラーをAIで自動図化した結果の一部。メガソーラーは国土基本情報の地図記号には含まれないが、例えば2次メッシュ534060の範囲内(我孫子市付近)では72箇所約18.3haのメガソーラーが存在することが分かった。メガソーラーの自動図化では、自動図化機構の後処理工程でAIが抽出した太陽光パネルの画素を膨張させて周囲のパネルの抽出結果と結合させ、さらに収縮させることでメガソーラーとしての範囲に変換している。このような処理も自動的に行われる。

※図化には27太陽発電設備16層3200枚モデル(F=0.874)を使用。太陽光発電設備の場合、512×512サイズを入力とする18層モデルの最高性能はF=0.844であり、256×256サイズを入力とするCNNの方が抽出性能が良い。

6. 社会実装に向けて




2017年撮影の写真の普通建物の自動図化結果



2021年撮影の災害発生直後の写真の自動図化結果

差分



消失建物の推定(災害後の写真入手後40分で作成)

これは本研究史上、自動図化機構として最初の図化事例である。

3枚の空中写真を使用し、所要時間は、カメラパラメータ方位角補正※に20分。自動図化に15分。差分作成に5分であった。

ただし、2017~2021年の間の災害に依らない消失建物も含まれる。

【解説】

3枚とも国土地理院が撮影した空中写真ナマ画像から本研究で開発した自動図化機構を用いて普通建物を地理空間情報化し、地理院地図上でオルソ画像と重畳表示させたもの。

実災害時は、オルソ画像より早く図化結果が取得できる。

地上画素寸法20cm相当の撮影画像に対応。

※カメラパラメータ方位角補正は、カメラパラメータが平面直角座標系で計算されている場合に子午線収差分を補正するもの。この当時原因不明であったため手動で補正していた。

6. 社会実装に向けて

- 本研究で構築した学習データ等は、国土地理院技術資料として国土地理院HPから公開

https://gisstar.gsi.go.jp/gsi-dataset/index_ja.html



The screenshot shows the 'GSI データセット' (GSI Dataset) page. It includes a '概要' (Summary) section with text explaining the dataset's purpose and a grid of six images showing different features extracted from aerial photos and colored: roads (red), water (blue), breakwaters (yellow), and other features like fields and buildings.



- 推論用プログラム
- 各項目の学習済みモデル
- 自動図化機構※
- $F \geq 0.6$ の項目の学習データ

も公開の方向で準備中。

※自動図化機構は、地上画素寸法20cmで撮影された空中写真画像データに対して最適化されており、使用にあたってはそれに対応したカメラパラメータが必要です。空中写真画像データとカメラパラメータいずれも（一財）日本地図センターから購入できます。

7. 目標達成状況

【数値目標】

① **40項目以上**の地物に対し、基盤地図情報の精度の範囲内で人が判読した場合に匹敵する抽出成功率の達成

➡ 人が判読した場合に匹敵する抽出成功率達成は12項目 <未達成>

➡ 全項目で2500レベルの位置精度を達成

② 抽出対象となる地物数全体の**80%程度**の抽出

➡ ①を達成した12項目のシェアは79.15%

ただし、太陽光発電設備に関しては国土地理院にデータが無いため、この数値には含んでいない。

7. まとめ

【本研究の目的】

「図化」の工程の**ブレークスルー**を実現する地物抽出AIの構築



いくつかの地物で**「自動図化」**を実現

図化工程の「ブレークスルー」への道筋をつけた

これからの地図の作り方と人との関係を
根本的に変えていく嚆矢となったか。

参考資料

個別AIの推論例は、 $F \geq 0.500$ の項目を掲載

用語の説明

・畳み込みニューラルネットワーク(Convolutional Neural Network)

入力側から次の層の値を算出する際に畳み込み演算を用いるニューラルネットワーク。画像を処理する際に用いられることが多く、畳み込み演算に用いるフィルタのサイズや演算間隔によってさまざまな効果が得られる。

・U-Net構造(のニューラルネットワーク)

CNNの中身を図にしたときに、入力から出力に向かってU字型に層(レイヤ)が描かれる。U-Netという医療用のCNNがそのような構造を取っていたことから、U-Net構造と呼ばれるようになった。

本研究で用いているU-Net構造は、Conditional-GAN(Isola他, 2017)の発生器に用いられているものとほぼ同じ16層のものを18層に拡張して使用している。細い線状地物である06普通鉄道のみは、形状補正のためにさらに1x1フィルタを追加した20層のCNNを使用。

・GPU(Graphics Processing Unit)

もともとは画面表示を高速化するための専用部品だったが、深層学習用のライブラリで使えるようになってからは深層学習を高速に実施するために必須の部品となった。

本研究では、学習には主にGeForce RTX3090とRTX3080Tiを、推論にはGeForce RTX2080TiとGTX1080Tiを、実装系の推論にはQuadro RTX8000を使用している。

用語の説明

・GAN(Generative Adversarial Networks:敵対的生成ネットワーク)

入力画像から(偽)画像を生成する発生器(Generator)と、発生器が生成した偽画像と正解画像を比較して偽であることを見破る判別機(Discriminator)で構成されるニューラルネットワーク。

発生器は判別機をだませる(正解にできるだけ近づけた)画像を生成するよう学習され、判別機は、どれだけ正解に近い画像でも発生器が作成した画像は偽と見破るように学習される。発生器と判別機が競い合って学習する様から「敵対的生成」と呼ばれる。

本研究着手当初はGANを使用していたが、良いモデルでもF=0.7程度で抽出性能が頭打ちとなったため、初年度のみの使用に留まった。

・ハイパーパラメータ

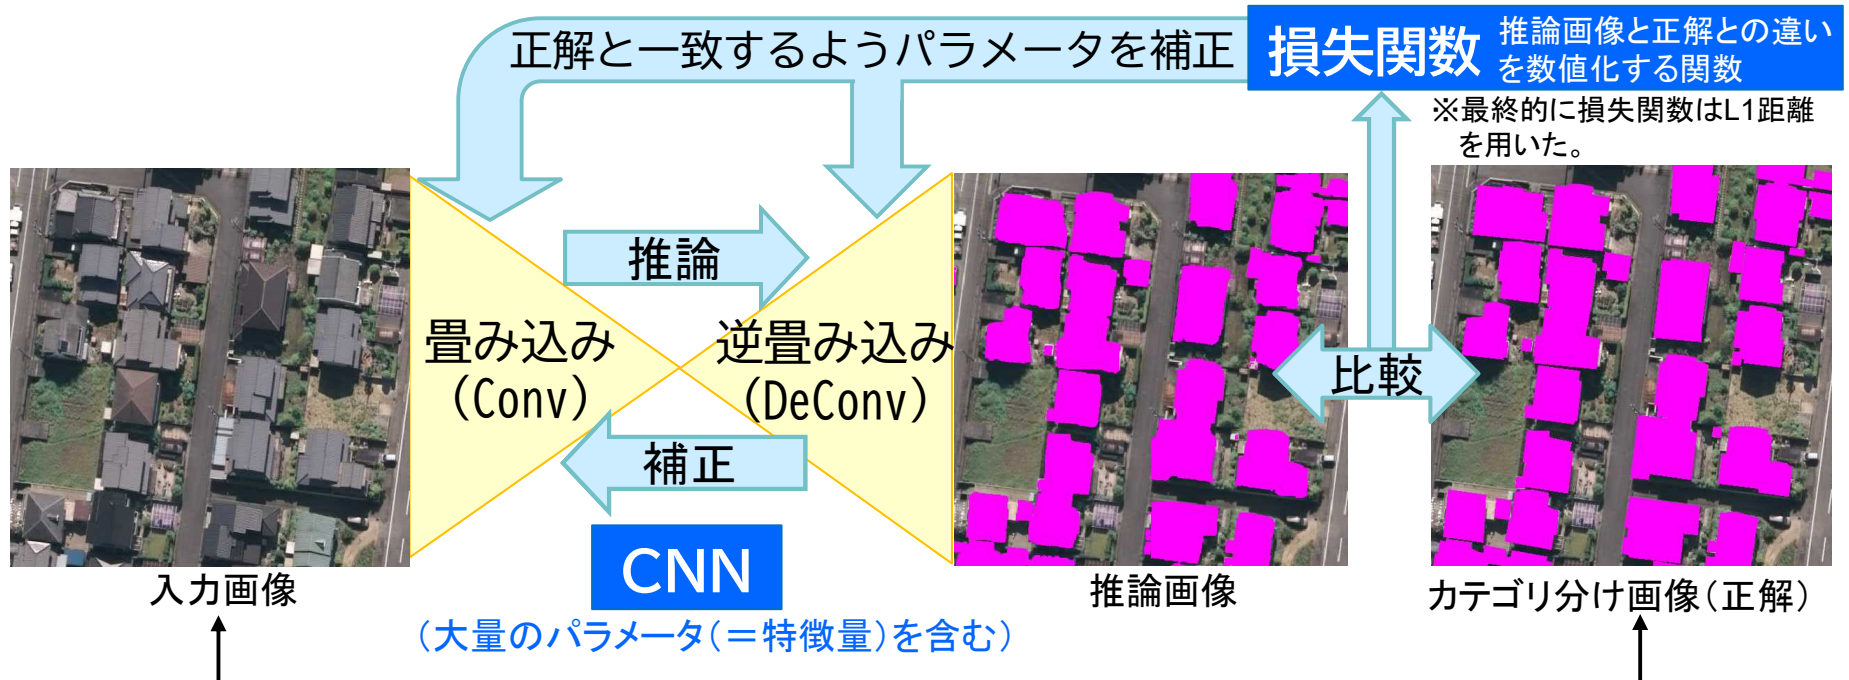
深層学習においてはCNNの大量のパラメータが自動的に計算されていくが、深層学習を実施するにあたって人間が決定するパラメータのことをハイパーパラメータと言う。

どのようなCNNを使用するかを含め、学習回数(実回数を表すステップ数や、学習データ1セットを反復して学習させる回数を表すエポック数)、深層学習での補正量を許容する割合である学習率、深層学習で何枚の画像を一度に計算させるかを表すミニバッチサイズ、損失関数をどのように設定するかなどが含まれる。

ハイパーパラメータをどのように設定するかで学習済CNNの性能が大きく左右されるため、本研究ではハイパーパラメータの探索に前半の3カ年を費やしている。

本研究におけるAIとは(深層学習とは)

- ・ 深層学習には「学習データ」「損失関数」「CNN※」を用いる
- ・ 欲しいのは「入力画像をより正解に近く変換できる特徴量」



この2つのセットを大量に用意したものを = **学習データ**

大量の学習データを使って損失関数の出力を0に収束させる (=正解と一致させる) 方向に推論とCNNのパラメータの補正を繰り返す。パラメータの値は次第に様々な特徴量を反映した値となっていく。

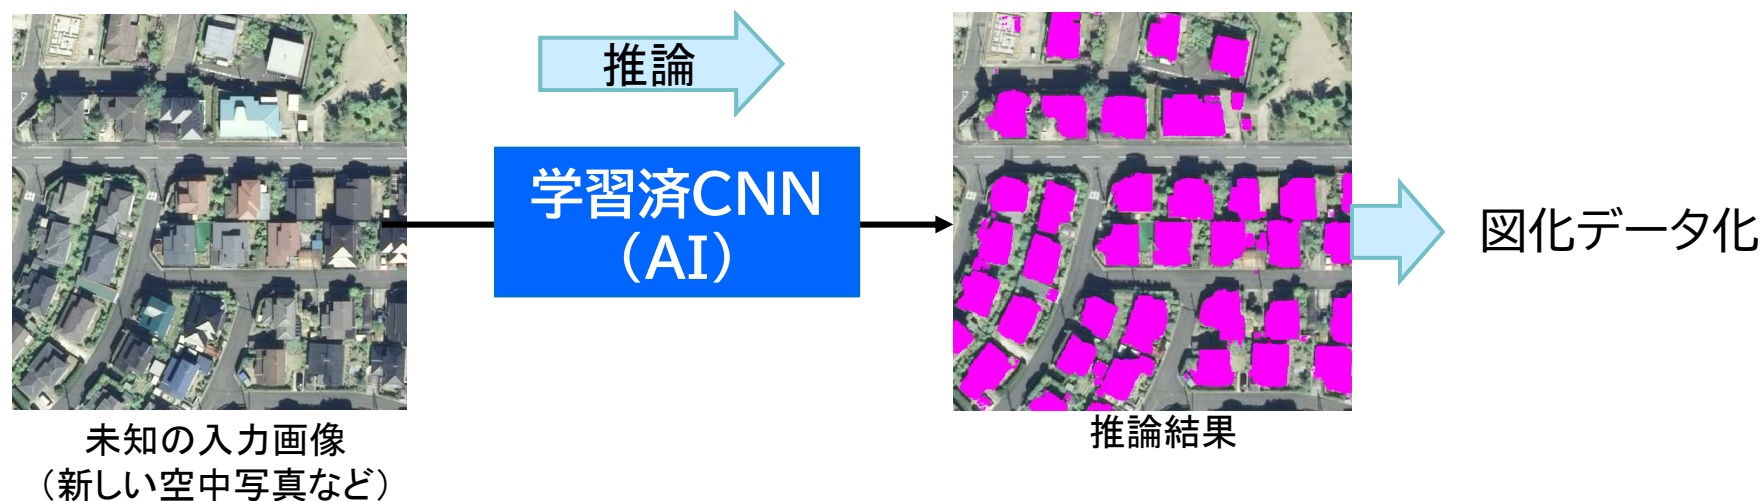
深層学習

本研究では、「深層学習したCNN (学習済モデル)」のことを「AI」と呼ぶ。 27

※CNN: Convolutional Neural Network(畳み込みニューラルネットワーク)

AIの使い方(学習済モデルによる推論)

- 深層学習を終えたCNN (AI) には、様々な特徴量が習得されており、そのまま推論に使用できる。

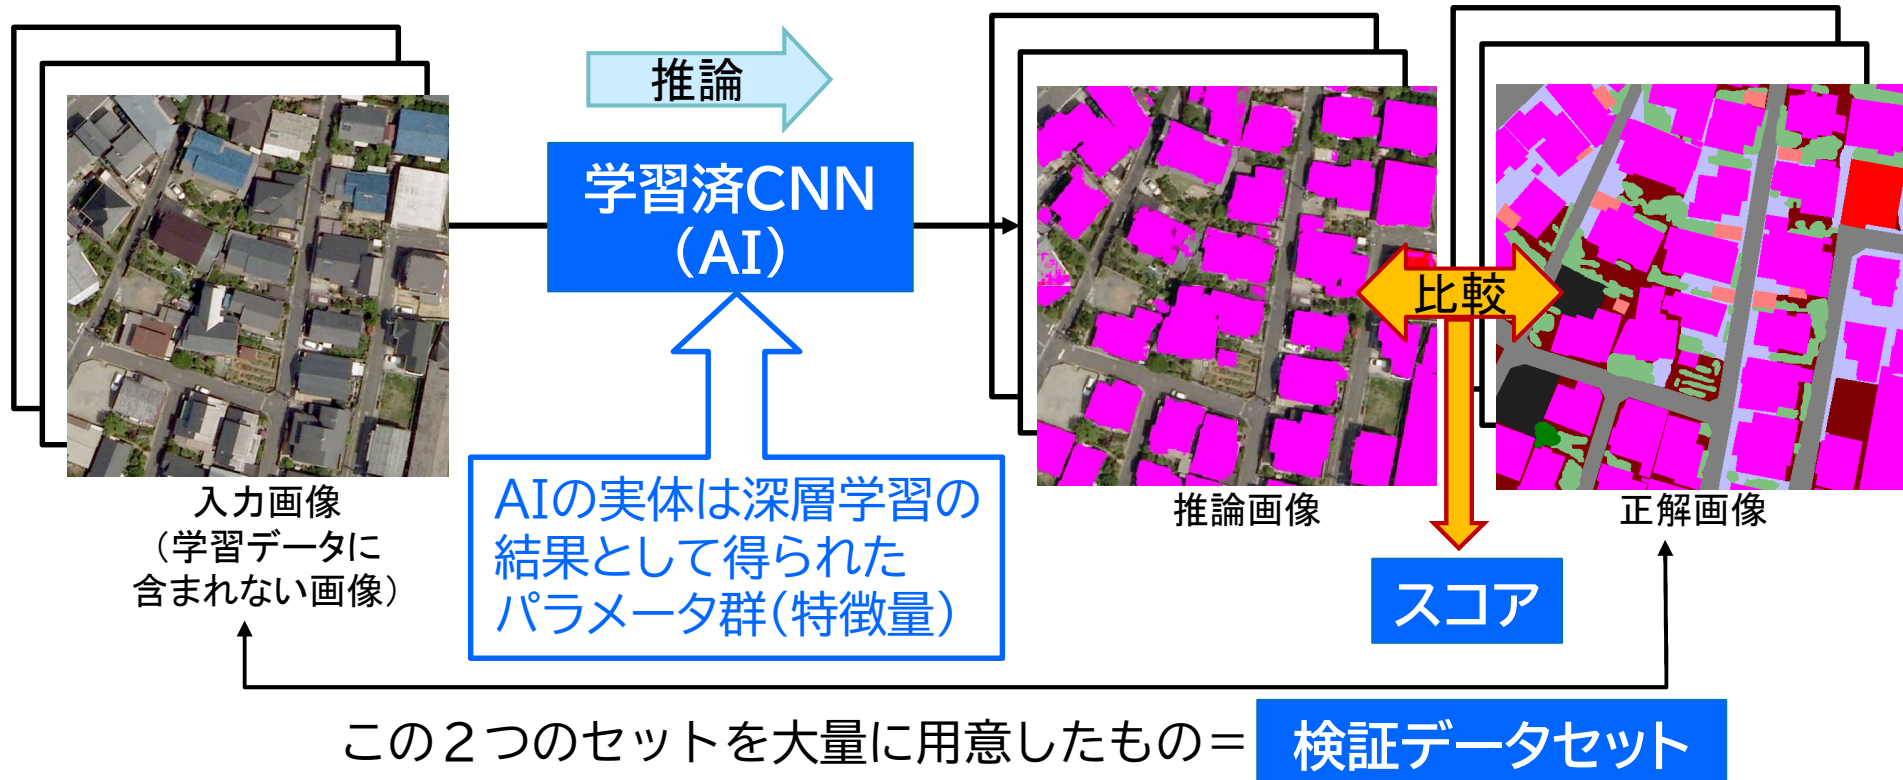


AIを使う際に、新たな学習は原則不要*。
 使用時は、推論のみが行われるため、処理速度が非常に高速になる。
 かつ、深層学習したモデルの推論精度は、従来法より高くなることが多い。

*ファインチューニングという学習を短時間行って、個別データへの適合性をより高めたうえで推論を行う場合や、転移学習と言って、CNNのパラメータ(習得された特徴量)の一部を転用して別のCNNに変更する学習を行う場合もある。

AIの性能評価(スコアの算出)

- AIの性能は、検証用のデータの推論結果によって客観評価する
- 検証用のデータが途中で変わると性能が比較できないため、本研究では専用の「検証データセット」を作成し、それを性能評価に用いた




検証データから推論した画像とその正解を比較※することでスコアが算出される。スコアの算出方法には、F値 (F1-Score)、IoUなどがあるが、本研究ではF値を用いて評価する。

カテゴリ分類の定量評価指標 (F値)


検証データ入力画像



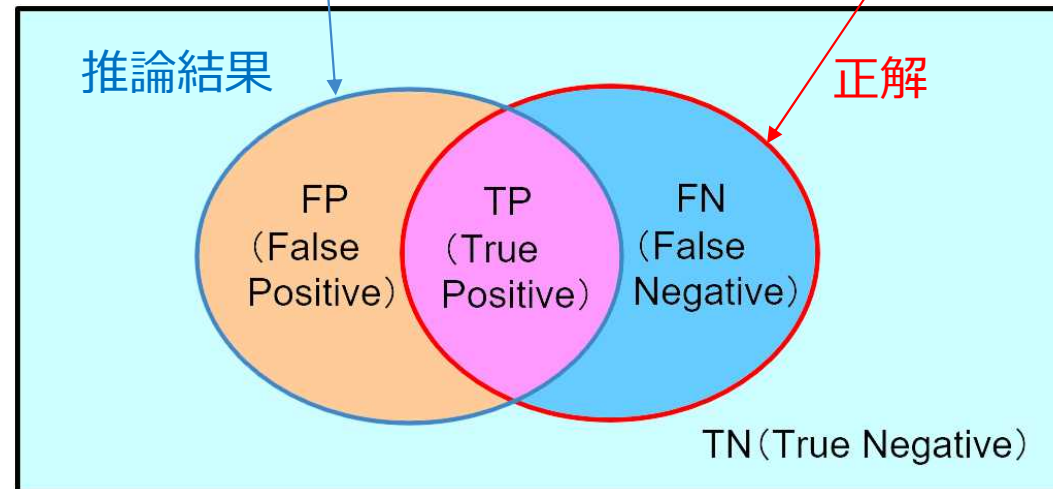
推論結果



検証データ(正解画像)



評価値
算出*



※評価値の算出方法

- ① 適合率 (Precision) = $TP / (TP + FP)$
- ② 再現率 (Recall) = $TP / (TP + FN)$
- ③ F値 (スコア) = $\frac{2 \times Recall \times Precision}{(Recall + Precision)}$

	正解が1	正解が0
推論結果が1	TP	FP
推論結果が0	FN	TN

※Accuracy(正解率)は存在率が小さい地物の場合適切な評価値とならないため、評価には一切使用していない。例えば、58砂礫地960枚モデルのF値は0.212だがAccuracyは0.992、41風車640枚モデルのF値は0.465だがAccuracyは0.9999である。

項目別の占有率(数値目標2の算出用)

項目	占有率	達成	項目	占有率	達成	項目	占有率	達成
02・03道路	24.58	●	20針葉樹林	2.29	○	54芝地	0	
04駐車場	0	○	21茶畑	0.06	●	58砂礫地	2.50	
05分離帯	0.23	○	22果樹園	0.39		61たたき	0	
06軌道	0.22	○	23荒地	0.54		63高塔	0.00	○
07水部	9.35	●	26しの地	0.08		65湿地	0.04	
08堅牢建物	1.60		27メガソーラー	0	●	67園庭	0	
09普通建物	44.99	●	28輸送管	0		68墓地	0.04	●
10無壁建物	5.31		36雪覆い等	0.00				
13水制	0.12	●	38プラットホーム	0.01				
14横断歩道橋	0		39タンク	0.01	●			
16畑	2.29		40広葉樹林	2.36				
17水田	2.93	○	41風車	0.00				
19竹林	0.05	○	44防波堤	0	●			

※占有率の単位は(%)。小数点以下3桁目を四捨五入。


※36雪覆い等は0.001%。41風車は0.001%、63高塔は0.0004%。ただし、63高塔のデータに送電線の鉄塔は含まれない。

※占有率が「0」の項目は、国土地理院の地図データベースにデータ種別が存在しない項目。

※OR型のAIと自動図化機構により単写真より実質的にPrecision、Recallが向上するため、達成した項目の全数を加算。


※●は数値目標達成項目、○は数値目標は未達成だが「人間が判読した場合に匹敵する」と思われる項目(○は数値目標には未算入)

個別AIの抽出例(04駐車場)



検証用入力画像の1枚
CSI-2021-1-W-C05_0019
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同じ)

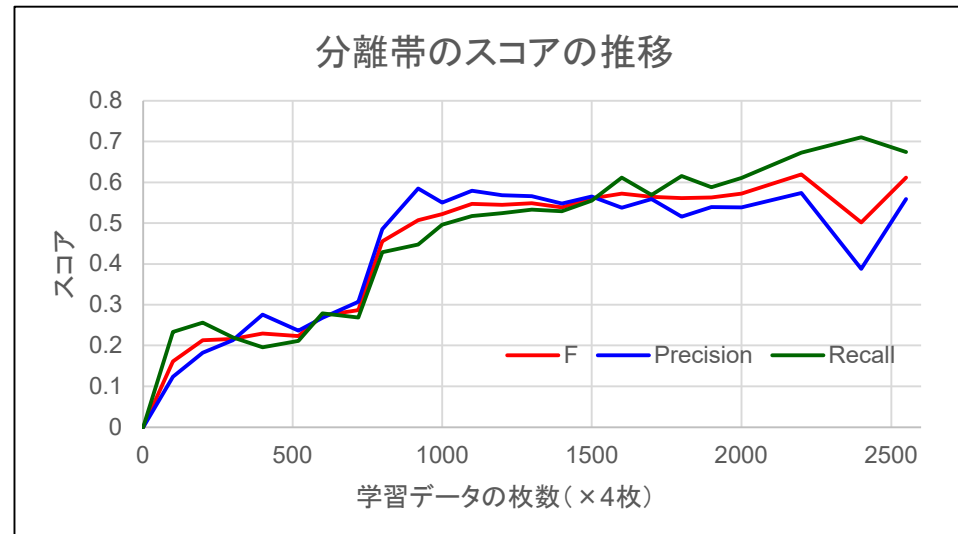
1700枚モデル(F=0.779)
による推論結果
(駐車場を赤色に色付け)



個別AIの抽出例(05分離帯)




検証用入力画像の1枚
CSI-2018-1-N-C01_0011
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同じ)




2200枚モデル(F=0.619)
による推論結果
(分離帯を赤色に色付け)

※760枚時点で検証データ648枚のうち9枚が不適切(入力画像のままであった)であったことが判明し、補正している。
※2150枚まで18層モデル、2200枚以降は20層モデルを使用

個別AIの抽出例(06普通鉄道)




検証用入力画像の1枚
CCG-2018-4-N-C07B_0027
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同じ)




1750枚モデル(F=0.712)
による推論結果
(軌道を黄色に色付け)

※1400枚以降20層モデルを使用

個別AIの抽出例(07水部)




検証用入力画像の1枚
62番

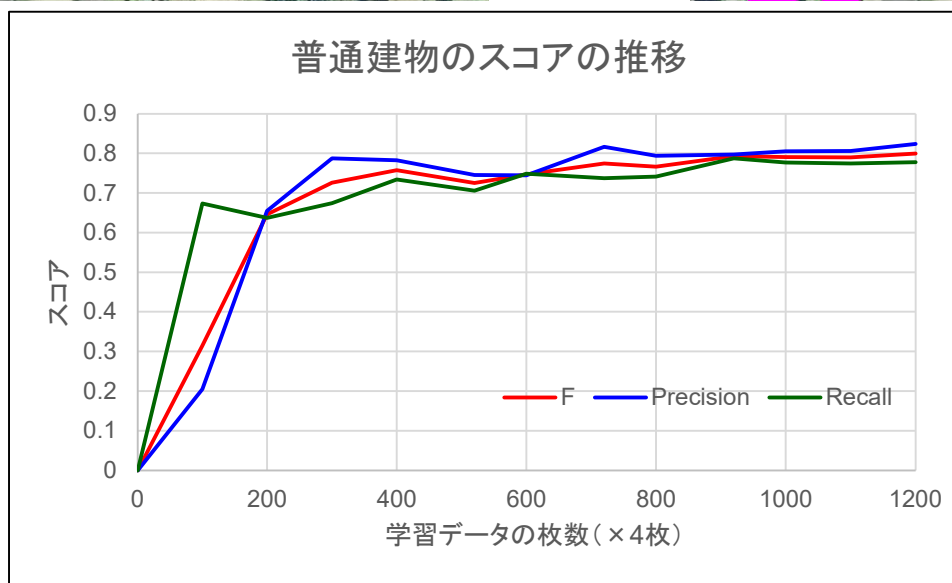


1250枚モデル(F=0.820)
による推論結果
(水部を青色に色付け)

個別AIの抽出例(09普通建物)




検証用入力画像の1枚
125番




1200枚モデル(F=0.800)
による推論結果
(普通建物をマゼンタに色付け)

個別AIの抽出例(10無壁建物)



検証用入力画像の1枚
202番




600枚モデル(F=0.688)
による推論結果
(無壁建物を黄色に色付け)

無壁建物の対象には温室を含む

個別AIの抽出例(13透過水制)




検証用入力画像の1枚
 CKK-2019-1-S-C08_0051
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。推論結果も同じ)




920枚モデル(F=0.801)
 による推論結果
 (透過水制を黄色に色付け)

個別AIの抽出例(14横断歩道橋)




検証用入力画像の1枚
 CKK-2019-1-S-C08_0051
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。推論結果も同じ)




1300枚モデル(F=0.557)
 による推論結果
 (横断歩道橋を赤色に色付け)

個別AIの抽出例(17水田)



CCB-2021-3-N-C05_0008
(Slide18の黒枠内と同じ範囲)

2450枚モデル(F=0.780)
による推論結果
(水田を水色に色付け)




個別AIの抽出例(19竹林)



検証用入力画像の1枚
 CKU-2018-5-E-C14_0012
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。推論結果も同じ)

1600枚モデル(F=0.608)
 による推論結果
 (竹林を赤色に色付け)




個別AIの抽出例(20針葉樹林)



竹林検証用入力画像の1枚
 CKU-2018-5-E-C14_0012
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。推論結果も同じ)

針葉樹林の検証データに
 本画像は含まれない。
 竹林との比較のために推論して
 みたもの。

760枚モデル(F=0.679)
 による推論結果
 (針葉樹林を赤色に色付け)



個別AIの抽出例(21茶林)



茶林検証用入力画像の1枚
CCB-2020-1-E-C06_0013
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同じ)


640枚モデル(F=0.830)による推論結果
(茶畑を赤色に色付け)

茶畑は検証データセットの完成が2022年冬と遅く、スコア算出開始時の640枚モデルで $F \geq 0.800$ を一発クリアしたため、スコアの推移グラフが存在しない。

個別AIの抽出例(27太陽光発電設備)




太陽光発電設備検証用
 入力画像の1枚
 CKT-2019-16-N-C13_0003
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。推論結果も同じ)




680枚モデル(F=0.844)
 による推論結果
 (太陽光発電設備を黄色に
 色付け)

個別AIの抽出例(38プラットフォーム)




プラットフォーム検証用入力画像の1枚
 CKU-2018-5-E-C10_0022
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小して表示。推論結果も同じ)




2050枚モデル(F=0.674)による推論結果
 (プラットフォームを黄色に色付け)

個別AIの抽出例(39タンク)




タンク検証用入力画像の1枚
CKT-2019-1-S-C01_0036
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同じ)



536枚モデル(F=0.855)
による推論結果
(タンクを赤色に色付け)

個別AIの抽出例(41風車)




風車検証用入力画像の1枚
 CKK-2019-1-S-C06_0015
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。)


620枚モデル(F=0.513)
 による推論結果
 (風車を赤色に色付け)

風車検証用入力画像の1枚
 CKK-2019-4-S-C04_0007
 (3000x3000サイズで推論。
 本画像は1500x1500に縮小
 して表示。)


620枚モデル(F=0.513)
 による推論結果
 代表的な誤抽出の例



個別AIの抽出例(44防波堤)





防波堤検証用入力画像の1枚
CHO-2018-1-E-C04_0010
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同様。)




1340枚モデル(F=0.815)
による推論結果
(防波堤を黄色に色付け)

個別AIの抽出例(63高塔)



高塔検証用入力画像の1枚
CCB-2020-5-E-C03_0034
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同様。)


高塔のスコアの推移




2800枚モデル(F=0.617)
による推論結果
(高塔を黄色に色付け)

国土基本情報では送電線の鉄塔
は含まないが、準則の標準図式では
対象に含まれるため、本AIは
送電線の鉄塔も抽出対象としている。

個別AIの抽出例(68墓地)



墓地検証用入力画像の1枚
CSI-2018-1-N-C01_0011
(3000x3000サイズで推論。
本画像は1500x1500に縮小
して表示。推論結果も同様。)



1700枚モデル(F=0.806)
による推論結果
(墓地・墓碑を赤色に色付け)