

## 第3章 全国の建物等に設置されているPVの導入状況調査（AI解析）

本章では、第2章で整備したデータをもとに、AI解析等を用いて全国の建物等に設置されているPVの導入状況調査について記載している。

全国の建物等に設置されているPVの導入状況について調査手順を図3.0-1に示す。

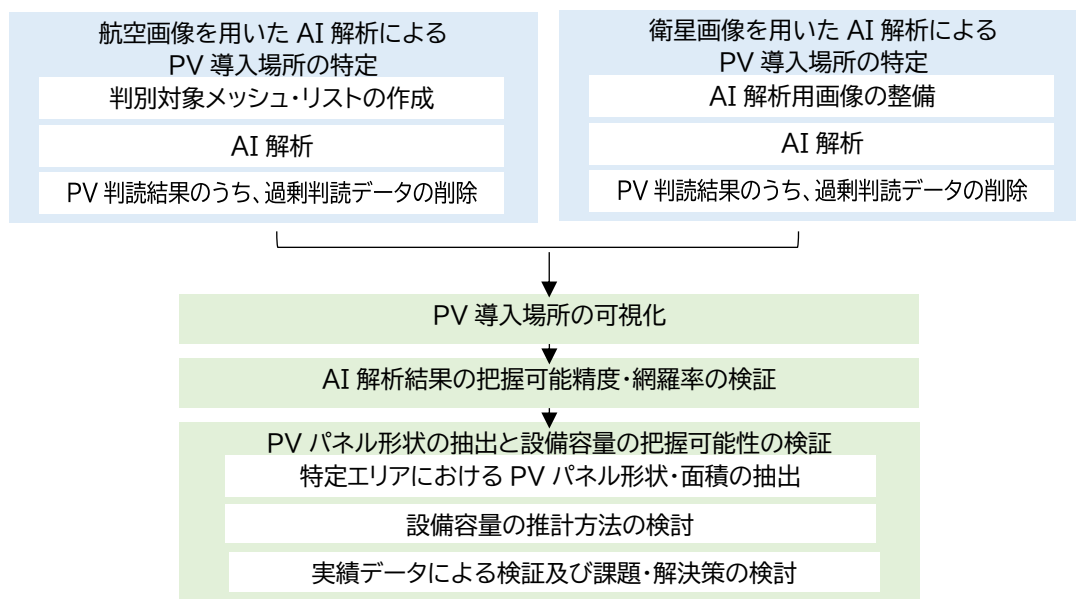


図 3.0-1 全国建物等に設置されている PV 導入状況調査の手順

### 3.0.1 使用する PV 判読システムの特徴

PV 導入場所の特定は、PV 抽出で実績のある AI 物体検出技術を活用した、オービタルネット社製航空画像判読ツール『Geo Detector』（以下、PV 判読システム）を用いた。PV 判読システムは、ディープラーニングの物体検出技術を応用し、建物上の PV を検出し、PV を内包する短形として抽出し GIS データとして、短形ポリゴン及びポイントデータとして記録するものである。




図 3.0-2 (左) 一般的な物体検出 (右) 物体検出を応用した地物検出

また PV 判読システムは、AI 解析用画像の整備、AI 解析、AI 解析結果の GIS データ化、の一連の工程を一つのコマンドで実施する※。検出後の PV 判読結果は、後工程で実施する過剰判読データ削除等で、作業者が可視化判断しやすい短形ポリゴンの状態でデータベースに登録する。その後、過剰判読データ削除等のすべての編集作業実施後、短形の代表点ポイントデータを生成し、データベースに再登録する流れとなっている。

※実際には全国 5 分割して、分割したデータセットの判読が完了後、結果を可視化確認したのち、データベースに登録する。

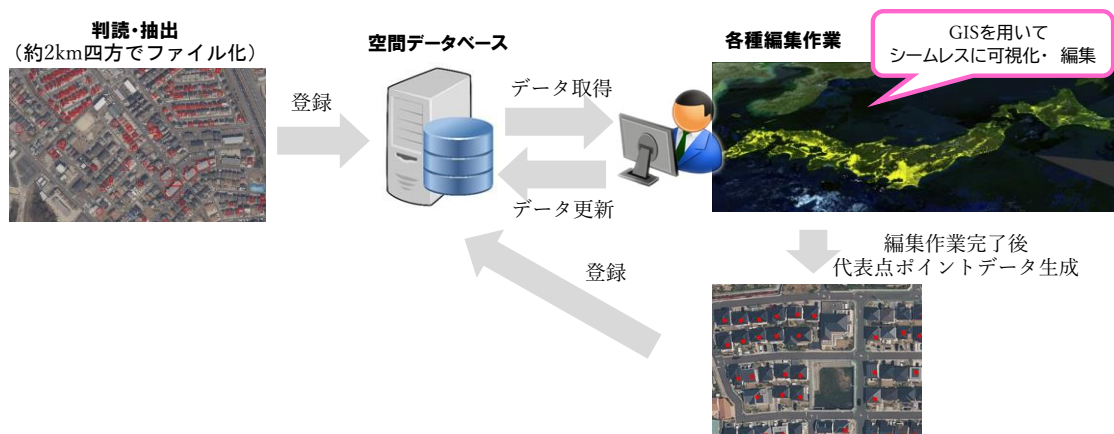


図 3.0-3 AI 分析による建物ソーラー場所の特定の流れ

### 3.0.2 AI 解析における課題と対応

第 1 章で航空画像及び衛星画像の特性から AI 解析において下記の課題が想定された。

- ・解析元となる画像に起因するもの
- ・PV 判読システムの性能に起因するもの

画像の地上解像度や画質が低い場合は、対象となる物体の検出もしづらくなる。これは人

間でも AI でも同様である。また、PV 判読システムの性能に関しては、教師データのサンプリングや使用する畳み込みニューラル・ネットワーク・モデル※や、学習の改善により改善する余地が大いにある。但し現状のシステムにおいて直ちに行えることは限られている。そこで現状把握している課題とその対応策について整理した。できる限り対応することによって全体の精度向上を目指すこととした。

※物体や顔、シーンを認識するために画像の中からパターンを見つけるのに特に有効なニューラル・ネットワーク。

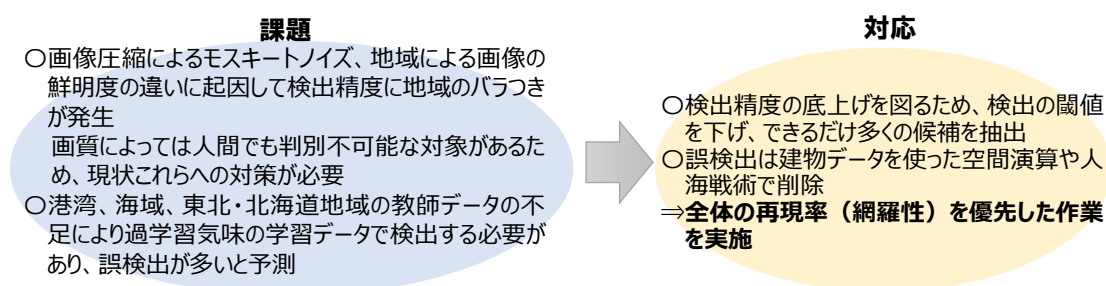


図 3.0-4 AI 解析における課題と対応

### 3.1 航空画像を用いた AI 分析による PV 導入場所の特定

図 3.1-1 は、航空画像を使用した AI 解析のイメージである。NTT インフラネット社から提供を受けた画像データセットを加工することなく、PV 判読システムの環境に接続していることが特徴である。(加工は PV 判読システムが自動で実施) また、対象となる判読範囲の設定も 3.1 (1) で後述するとおり、専用ツールを作成している。

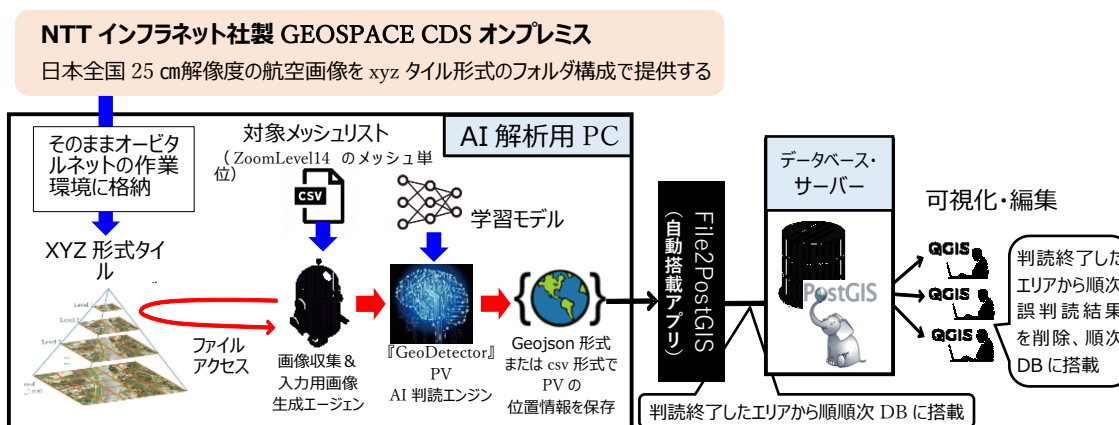


図 3.1-1 航空画像と AI を用いた PV 導入情報の把握工程のイメージ

#### (1) 判読対象メッシュ・リストの作成

判読システム用の解析範囲を設定するため、PV 判読システムの補助ツール『タイルメッシュ生成 QGIS プラグイン※』を用いて、日本全国を対象にメッシュ分割した。このメッシュが一つの処理単位となり、GIS データもこのメッシュ単位で生成される。このメッシュの大きさは XYZ タイルのズームレベルの範囲で自由に設定できるが、高いズームレベルで設定するほど無駄な判読領域が減少し、生成される GIS データファイル数が増える。そこでバランスをとり XYZ タイルのレベル 14 にあたる約 2 km 四方のメッシュデータファイルを生成した。

※オープンソースのデスクトップ GIS ソフトウェア “QGIS” に組み込んで使用する




図 3.1-2 メッシュイメージ（東京都を中心とした範囲）

## （２） 航空画像を用いた AI 分析

### 1) 特定地域におけるテスト分析と網羅率の検証

全国の AI 解析を行う前に、一部地域（愛知県）での AI 解析を試行的に実施した。全体工程に余裕がないため、この時点でクリティカルな問題を把握・解決しておくことが目的である。

愛知県を対象に AI 解析で PV 抽出した結果を GIS に取り込み可視化した。問題なく検出処理が行われ、正しく位置情報が付与されていることを確認した。




図 3.1-3 PV 検出結果の可視化（愛知県）

#### ① テスト地域の選定と再現率の検証

ズームレベル 16 のメッシュ領域（約 500m×500m 四方）のうち、名古屋市近郊において PV 設置個所が多い 4 メッシュを選択した。次に対象のメッシュごとに、背景となる航空画像をもとに PV 設置建物を目視判読し、該当する建物（PV）をポリゴン入力した。AI 判読は PV を

囲う短形の重心が PV 判読結果のポイントとなるので、PV の設置形状に配慮しながらポリゴン入力を行った。

判読の条件として、確実に PV が設置されていることが目視で確認できること、またそれぞれのメッシュ領域に完全に収まっていない建物は評価の対象から除外することとした。

次に、PV を含む建物ポリゴンに PV フラグを立て、さらに PV 判読結果ポイントを含む建物に予測フラグを立て、PV フラグ建物総数に対する予測フラグ建物総数の割合から再現率 (Recall) を算出した。



サンプルエリア 1  
設置棟数 120 判読棟数 119 再現率 99.17%



サンプルエリア 2  
設置棟数 100 判読棟数 98 再現率 98.00%



サンプルエリア 3  
設置棟数 108 判読棟数 104 再現率 96.30%



サンプルエリア 4  
設置棟数 110 判読棟数 98 再現率 89.09%

Total 設置棟数 438 判読棟数 419 再現率 95.66%

図 3.1-4 航空画像 PV 判読結果の網羅率検証

## ② テスト結果に対する課題と対策

概ね良好な結果であったものの、名古屋市近郊は、PV 判読システムの重みモデルを作成するにあたり、初期の教師モデルの多くを使用した地域である。この地域で再現率 95%となると、他の地域を含めると 5 ポイントから 10 ポイント低下する恐れがある。そこで PV 判読システムの重みモデルに使用した畳み込みニューラル・ネットワーク・モデルと異なるモデルを用いて再度学習を行い、新たに重みモデルを生成した。この重みモデルを使用し再度 PV 判読を実施した。さらに前回実施した PV 判読結果をこれにマージ、改良 PV 判読結果として再現率を算出した。




サンプルエリア 1  
設置棟数 120 判読棟数 120 再現率 100.00%  
0.83 ポイント向上



サンプルエリア 2  
設置棟数 100 判読棟数 99 再現率 99.00%  
1.00 ポイント向上



サンプルエリア 3  
設置棟数 108 判読棟数 106 再現率 98.15%  
1.85 ポイント向上



サンプルエリア 4  
設置棟数 110 判読棟数 109 再現率 99.09%  
10.00 ポイント向上

Total 設置棟数 438 判読棟数 434 再現率 99.09% 3.43 ポイント向上

図 3.1-5 改良型手法航空画像 PV 判読結果の網羅率検証

3.43 ポイント向上と期待したとおりの結果であった。中には10 ポイント向上した地域もあり、これで全国対応しても問題ないと判断した。結論として前重みモデルと新重みモデルを用いて計2回の全国のPV判読を実施。これらをマージしたものを航空画像のPV判読結果とすることにした。

## 2) 全国のPV判読の実施

PV判読システムと航空画像データセットを用いて全国の対象109,655メッシュの処理を実施した。実際には全メッシュ・リストを5分割し、1セット終了するごとにGISで判読結果を可視化確認しながら全対象の処理を進めた。

AI分析は、ズームレベル19の画像（地上解像度約25cm）256px×256pxを縦横4枚接合して1枚のAI解析用画像として判読処理を行う。この作業は『画像収集&入力用画像生成エージェント』が自動的に処理する仕組みになっている。1メッシュ（約2km四方）を処理するには、上記判読処理を256回繰り返す。5秒にこの256回の判読が行われ1メッシュの処理が完了するため、ベンチマーク的には全メッシュが548,275秒（約6.3日）で完了し、2モデル合わせて13日弱で完了したことになる。参考にPV判読システムに使用したワークステーションのスペックを以下に示す。

表 3.1-1 PV判読システムに使用したワークステーションのスペック

CPU	Core i9-11900K(3.50GHz-5.20GHz/8コア/16スレッド)
メインメモリ	64GB DDR4 SDRAM
GPU	NVIDIA GeForce RTX3090 24GB
Primary Disk	2TB SSD
Secondary Disk	8TB HDD
OS	Ubuntu 20.04LTS



航空画像を用いた PV 判読結果を GIS で可視化した結果を図 3. 1-6 に示す。




図 3. 1-6 改良型 PV 判読結果の可視化

### (3) PV 判読結果のうち誤検出・過剰判読データの削除

本業務の目的が、AI 解析を活用してより現実に沿った PV 導入場所を特定することにあるとの認識のもと、誤検出・過剰判読データの削除作業を実施した。当初は以下の方針で実施する予定であった。

- ① 航空画像データ作成時点より建物データの作成時点が後であるもの  
⇒ 建物ポリゴンで差分を削除
- ② 上記以外のもの：地域を分割して人海戦術によって消去

#### 1) 航空画像と建物ポリゴンとの位置ズレ等の課題

①については、航空画像と建物ポリゴンとの位置ズレ箇所が多いこと、両者の経年変化によってデータの差異があり、作成時点が詳細に把握できないこと、建物形状が航空画像と比較して大雑把にトレースされている箇所があることなど、単純に建物ポリゴン以外の検出結果を除外すると、正の検出結果が多く削除される可能性があることから、建物ポリゴンで差分を削除することは見送った。とりわけ位置ズレに関する課題は、航空画像と衛星画像の間でも発生しており、本問題の解消は今後の重要課題である。詳しくは 3.2 (2) 5) で解説する。

#### 2) 人海戦術による誤検出データ等の削除

以下の建物 PV 以外の誤検出及び不適格検出箇所が稀に検出されることを確認している。これらの人海戦術で削除する。

ビニールハウス・ガラスハウス、畑上のビニールカバー、野立て PV、駐車場、屋根上のガラスパネル、その他明らかに野立て PV でないと判断できるもの、建物上に 2 件以上の抽出結果があるもの。

これらを検出結果全体の 1 % を目標に削除を実施した。その結果、全検出件数 3, 105, 306 件のうち 35, 811 件の不要データを削除し、削除後件数 3, 069, 495 件となった。時間の制約があったため、すべての不要データを削除することはできなかったが、機械的に削除が困難な不要データを一定数削除することができた。

但し、この作業は適合率に向上に寄与するが、網羅率が向上することはない。削除作業完了後、検出結果短形のポリゴンデータから代表点ポイントデータを生成し、空間データベースに登録した。

### 3.2 衛星画像を用いた AI 分析による PV 導入場所の特定

航空画像と同様に AI 解析ツール『Geo Detector』を用いて PV 導入情報を把握した。航空画像データセットとの解像度の違いにより、判読結果において 90%の再現率を求めることは困難と推察される。しかし衛星撮影は短期間で全国網羅性に優れており、今後の計画的なデータ更新の検討を見据え、衛星画像による AI 判読も実施した。

図 3.2-1 は、衛星画像を使用した AI 解析のイメージである。日本スペースイメージング社から提供を受けた画像データセットは 1 枚が約 10km 四方のメッシュサイズであるため、画像を分割して AI 解析用データセットを整備した。詳しくは後述するが、この画像分割も PV 判読システムの一機能であり、自動で作成される。




図 3.2-1 衛星画像と AI を用いた PV 導入情報の把握工程のイメージ

#### (1) AI 分析用画像の整備

第 1 章で、日本スペースイメージング社から提供を受けた衛星画像には、最新の撮影画像で構成される“vivid”データセットと、過去 5 年以内の晴天率の高い画像のみを接合して再構成した“Dynamic モザイク”データセットが存在していることを解説した。また、これとは別に関東地域のみではあるが、地上解像度 30cm のデータセットが提供されている。この 30cm の画像をもとに AI 解析を実施することも検討したが、一部地域であることと、この地域には航空画像の最新のデータセットが存在していることから、本業務での使用を見送り、結果として、最新の衛星画像の“vivid”データセットを本業務で使用することにした。

“vivid”データセットは、最新の画像であるゆえ、中には薄雲がかかっている地域もあり、部分的に“Dynamic モザイク”を使用することも検討した。しかし、全国の画像を精査してハイブリッド方式で整備することは容易でないことから最終的に“vivid”データセットのみ使用した。薄雲の地域も AI 解析を行った。




図 3.2-2 最新の衛星画像、“vivid” データセット

まず、衛星画像ファイルに埋め込まれている位置情報を解析し、Dynamic 図郭のデータ (5,743 図郭) を整備した。次にこの図郭データを GIS で可視化した。その結果、このデータセットは北海道の一部が欠如していることを確認した。のちに日本スペースイメージング社から不足分の図郭のみの画像データセットの提供を受け、日本全国、6,300 図郭を取り揃えた。




図 3.2-3 Dynamic 図郭で可視化した “vivid” データセット

また、Dynamic 図郭 (19,584px×19,584px) の画像から xyz タイル (256px×256px×ズームレベル) の画像生成するには、投影変換から行う必要があり、さらに日本全国の画像データを約数兆ファイルの生成作業を行うことは工程的に困難である。そこで、xyz タイルから AI 解析用画像を整備する方法は用いず、19,584px×19,584px の画像を AI 解析に最低な画像縦、横) サイズに単純に分割する方法を選択した。画像と位置情報の紐づけはワールドファイル、または GeoTIFF を自動生成することで対応した。

分割後のサイズはCDSの25cm解像度に対して50cm解像度であることを考慮して、500px×500px程度とする。Dynamic 図郭の画像（1ファイル19,584px×19,584px）を、最終的にAI解析に最適なサイズ(544px×544px)に分割し、約816万ファイルのAI解析用衛星画像データセットを整備した。

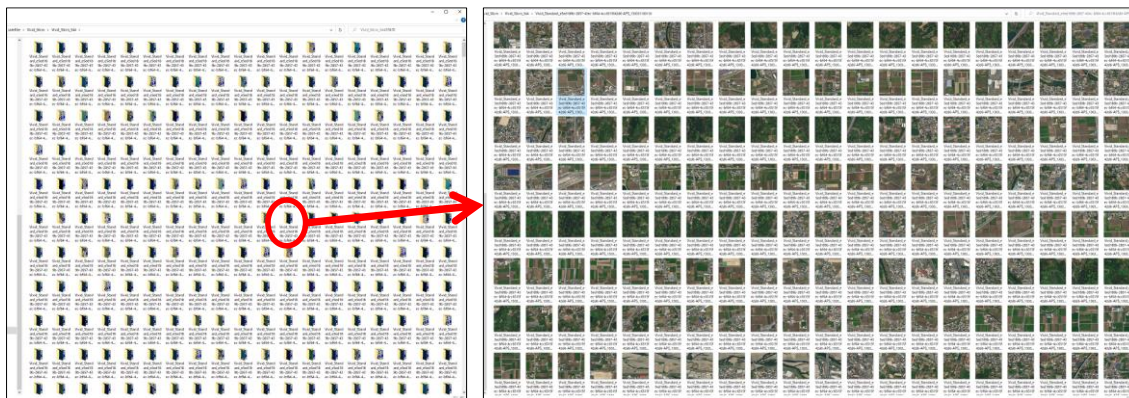


図 3.2-4 分割後の AI 解析用衛星画像データのイメージ

ファイルに直接アクセスして取得するため、Web サーバー経由で http アクセスして取得する航空画像の PV 判読システムと比べて高速にデータを取得処理することが期待できる。

## (2) 衛星画像を用いた AI 分析

### 1) 特定地域におけるテスト分析と網羅率の検証

#### ① 網羅率の検証

航空画像の AI 解析と同様、全国の AI 分析を実施する前に一部地域で AI 解析を行い、可視化を行った。(衛星画像を背景に用いると PV が識別できなくなるため PV 判読結果のみ)




図 3.2-5 衛星画像を用いたテスト AI 分析結果の可視化

この時点では、全国衛星画像のデータセットの提供を受けておらず、事前に提供を受けた4メッシュ分の画像のうち1画像(約10km四方)において解析を行った。さらに航空画像と同様にこの解析結果のうち、1km四方において網羅率の検証を実施した。



図 3.2-6 当初の衛星画像を用いた PV 判読結果の網羅率検証

## ②テスト結果に対する課題と対策

結果として、網羅率 11%にも満たない結果となった。考えられる要因として衛星画像の地上解像度が 50%であることに加え、モスキートノイズなど不可逆圧縮による画質の低下により、人間でも判読が難しい箇所が多い点である。このことは同じ地上解像度が 50%の航空画像では、網羅率 80%~90%を超えることから裏付けられる。

このような結果から、航空画像との共通のディープラーニングの重みモデルを使用することに無理があることを認識し、衛星画像専用の重みモデルを構築することが唯一の解決策と考えた。アノテーション作業に費やせる時間は約 1 ヶ月程度であったが、教師データを整備することから始め、さらに学習により専用の重みモデルを構築した。まずは、Vivid50 cmのサンプル画像から教師データセット画像 1,000 枚強のアノテーション作業を実施した。

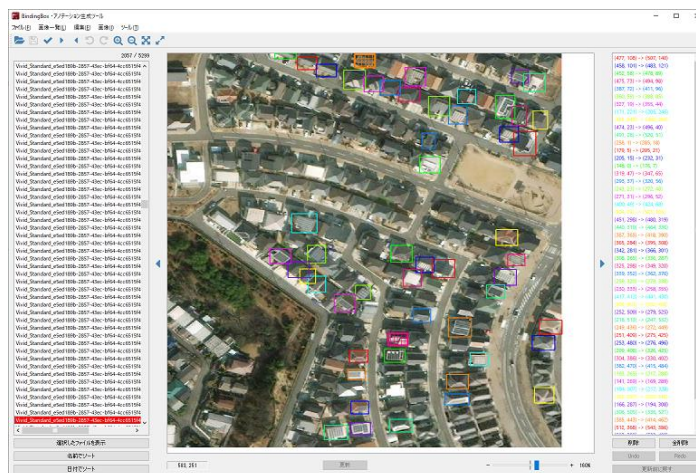


図 3.2-7 オービタルネット社製アノテーション・ツールによる PV 識別作業

一旦、アノテーション作業の途中段階で学習を行い、その結果得られた重みモデルを使用して、再度衛星画像を用いた PV 判読を実施した。その結果が図 3.2-8 である。航空画像の重みモデルを用いて衛星画像の PV 判読を実施した結果では、背景の衛星画像を使うと判読結果が識別できないほどの低い検出率であったが、途中段階ではあるが明らかに判読率が増しているのが可視化で読み取れる。



図 3.2-8 途中段階の改良版衛星画像 AI 分析結果の可視化

引き続きアノテーション作業を続け、最終的に有効画像 1,500 枚以上の教師データを作成し、水増しにより 6,000 枚程度の学習用データセットを作製した。さらにディープラーニングによる学習を行い、衛星画像専用の重みモデルを構築した。

衛星画像の場合、季節や日照条件、撮影方向によって品質に大きなばらつきがあるため（パネルの投影面積が圧縮されたり、建物の影で判別できなくなったり、太陽光の反射で判別できなかつたり、JPEG のノイズで屋根の模様と区別できなかつたりする）、安定した判読結果を得ることは極めて難しい。それでも人間が PV 判別できないような状況でも安定して判読できる AI モデルの構築を心掛けた。その結果、途中段階の判読結果より、さらに多くの PV を判読できるようになった。

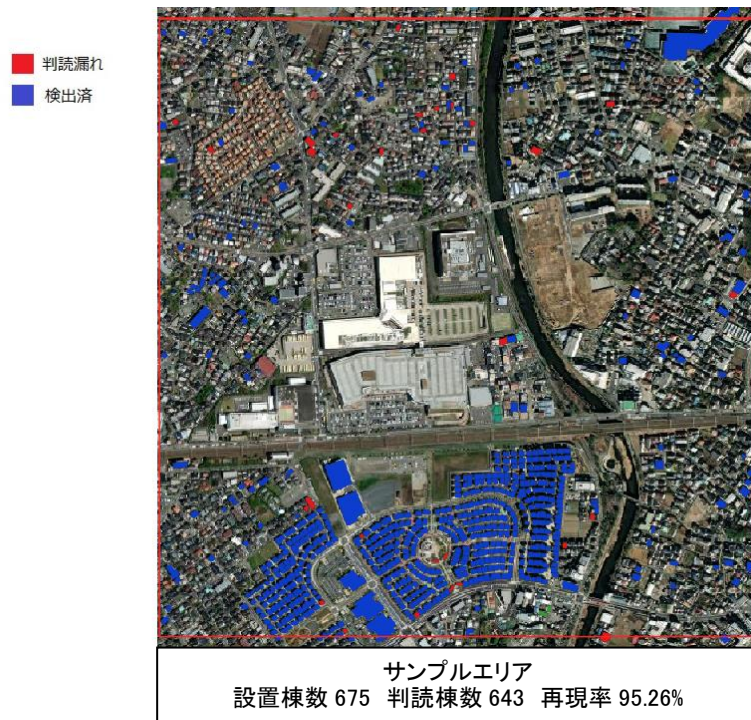




図 3.2-9 改良版衛星画像 AI 分析結果の可視化

工期的な制約から AI モデルの構築はここまでとしたが、精度向上の勘所が掴めたため時間が許せばさらなる精度向上が可能である。

さらにこの判読結果における再現率を算出した。



### 84.3 ポイント向上

図 3.2-10 衛星画像を用いた PV 判読結果の網羅率検証

衛星画像専用の重みモデルを構築し、これを用いて AI 解析を行った結果、当初の網羅率検証と比較して 84.3%の向上が図れた。時間の関係で一部地域でしか検証は行えなかったが、有効性は確認できた。すべての地域でこの結果が得られるわけではないが、当初目標の衛星画像を用いた AI 解析結果の網羅率 80%は概ねクリアできると考えられる。これ以降の検証は、航空画像 AI 判読結果とのマージを行った結果において総合的に評価する。



## 2) 全国の PV 判読の実施

PV 判読システムと衛星画像データセットを用いて全国の対象 6,300 メッシュの処理を実施した。航空画像データセットと異なり、AI 解析用の画像整備に画像分割という工程が入るが、のちに画像接合という処理が発生しないため、航空画像を用いた AI 解析より高速に処理が行われる。結果として日本全国の AI 解析が 5 日程度で完了した。

## 3) 衛星画像を用いた AI 解析における有用性の確認

最新の衛星画像データセット“vivid”を用いた AI 解析の有用性を確認するため、航空画像を用いた AI 解析結果と、経年変化箇所において比較検討を行った。比較対象地域は、航空画像 2016 年撮影 5 年の経年変化が懸念される愛知県内の 8 km×8 km の範囲内で、比較検討は目視によるものである。

下は、衛星 AI 分析結果を、GIS を用いて可視化した結果である。、GEOSPACE CDS を背景にした場合（左画像）、一見すると判読結果と一致していないように見える。しかし判読元の衛星画像を背景にするとその確からしさが見て取れる（右画像）。このように衛星画像による AI 判読は、GEOSPACE CDS の更新サイクルが 3 年以上の都市近郊や中山間地の経年変化を補う手段として有用・有効であることが実証できた。






図 3.2-11 航空画像の経年変化箇所における衛星画像 AI 解析結果

#### 4) 衛星画像の誤検出における課題と対応

日本全国の判読結果を可視化して確認したところ、建物以外に田畑を一定以上の大きさで誤検出していた。これは衛星データ専用の重みモデルを構築する際に、同様のパターンの教師データ量が足りないことと、検出の閾値を極端に下げたことに起因していると考えられる。最終的には建物データで除去できるが、事前に機械的に除去しておくことが望ましい。

特性としては検出の確度である probs 値が低く、検出矩形が大きいことから、probs 属性が 0.5 値未満のすべての検出結果、または probs 属性が 0.8 未満且つ検出矩形が大きい検出結果を全国一括除去することで対応した。中には実際に正の検出結果もあったが、本来 probs 属性が 0.5 値以下の結果は除去すべきためそれらも除去することとした。



図 3.2-12 衛星画像の田畑の誤検出（左：対策前、右：対策後）

#### 5) 航空画像 PV 判読結果と衛星画像 PV 判読結果とのマージにおける課題と対応

##### ①判読元が異なる2つの地物の相対的な位置ズレ

下記画像は、同じ領域で切り取った JIS 衛星画像、CDS 航空画像である。赤枠が衛星画像から判読した PV 短形、青枠が航空画像から判読した PV 短形である。双方を比較すると家屋1棟ほどのズレが生じている。どちらかが一方的にズレているわけではなく、それぞれの画像が位置的な誤差を含んでおり、その誤差が相対的な位置ズレを起こしている。GISなどでマッピングする場合、航空画像の PV 判読結果は航空画像を、衛星画像の PV 判読結果は衛星画像を背景画像にすることが1つの解決策となりうる。



図 3.2-13 判読元が異なる2つの地物の相対的な位置ズレ

## ②高層建物の傾きによる位置ズレ

真上から撮影されていない高層建物の傾きが正射変換されておらず、位置ズレを起こしているケースも多く存在する。2次元投影したPV判読結果は当然隣の建物や道路上に投影される。



図 3.2-14 建物の傾きによる位置ズレ

原因は、空中写真測量に基づいてピクセル単位で位置補正されたオルソ画像（精密オルソ）でないことである。空中写真の幾何補正にとどまっているものが多い。国土地理院の Web サイトにオルソ画像についての解説があるので以下に引用する。解決の方向性としては、ステレオ撮影した画像からオルソを作成していない衛星画像などでは、撮影時のオフナディア角（入射角）が深い（20 度以上）撮影画像を避けることが望ましい。

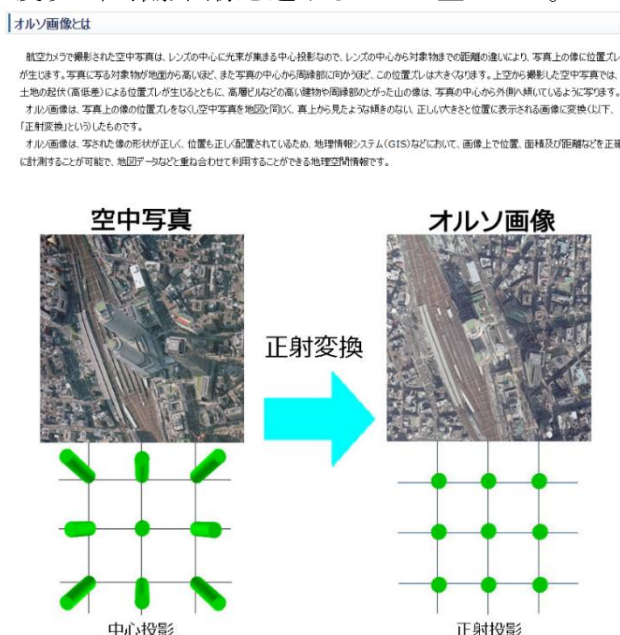


図 3.2-15 国土地理院 Web サイトにおけるオルソ画像の解説

出典：国土交通省国土地理院 HP

### ③ AI の検出の位置ズレにより建物形状から外れる可能性があるケース

屋根 PV は屋根形状によっては南側に設置されるため、検出が少しずれた場合、検出対象の画像位置情報と建物形状位置情報の誤差によって検出ポイントが建物形状から外れる可能性がある。本課題については、建物形状にバッファ（3m 程度）を持たせることで許容することができる可能性がある。



図 3.2-16 AI 検出における位置ズレ

### (3) PV 判読結果のうち誤判読・過剰判読データの削除

衛星画像 PV 判読結果は、航空画像 PV 判読結果の判読元画像の時点が古い地域を補完するためにマージすることを前提としている。このため、衛星画像の時点が新しい地域をすべて使用することが理想であるが、3.2 (2) 5) で解説したとおり、航空画像 PV 判読結果との位置ズレが懸念されるため、なるべく航空画像分析結果と時点が近い衛星画像分析結果を使わず、時点が 2 年を超えた地域の検出結果のみ使用することとした。

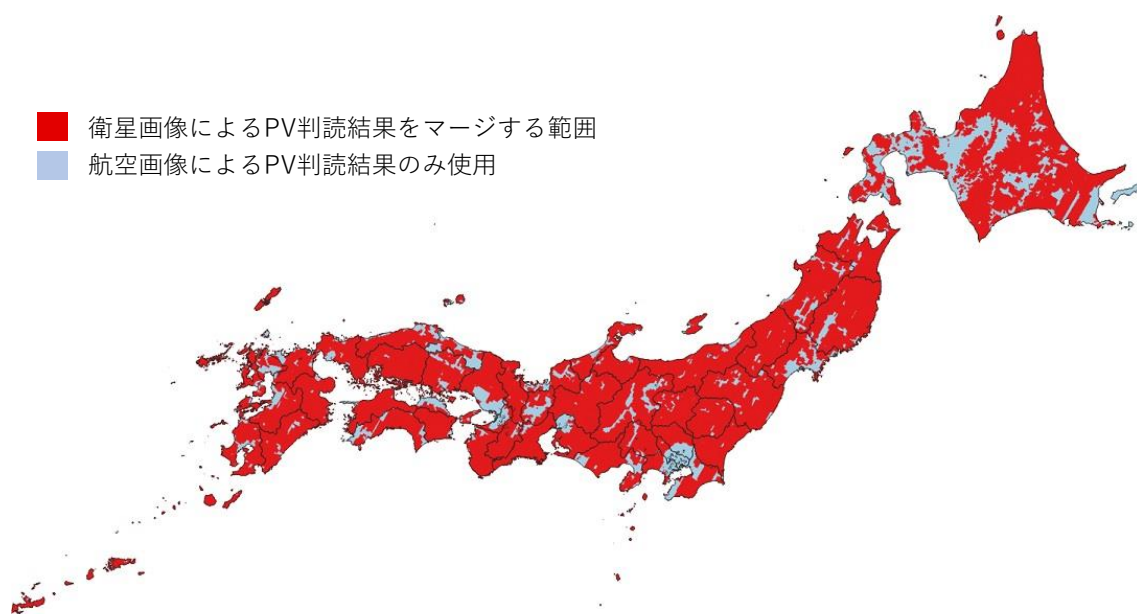


図 3.2-17 衛星画像 PV 判読結果のうち、航空画像 PV 判読結果のマージに使用する範囲

上記マージする範囲外の判読結果を削除することを前提に、PV 判読結果の誤判読・過剰データの削除を以下の工程で実施した。

- ① GEOSPACE CDS と撮影時点が 2 年以内の地域の検出結果を削除
- ② 前述、3.2 (2) 4) で実施したフィルタリング処理
- ③ 人海戦術による手動削除 (航空画像 PV 判読結果と同様の誤判読・過剰データを削除)
- ④ 航空画像 PV 判読結果の検出短形の範囲に含まれる、衛星画像 PV 判読結果ポイントを削除

①～④の順に誤判読・過剰判読データの削除を行った結果を以下に示す。

衛星画像を用いた PV 判読件数	2,278,999 件
①による削除処理	⇒ 1,332,605 件
②によるフィルタリング処理	⇒ 1,101,946 件
③による手動削除処理	⇒ 1,028,499 件
④の空間演算による削除	⇒ 631,529 件

#### (4) 航空画像 PV 判読結果と衛星画像 PV 判読結果とのマージ

上述 3.2 で実施した航空画像を用いた AI 分析結果と本項で実施した衛星画像を用いた AI 分析結果ポイントデータにマージした。

その結果、航空画像を用いた PV 判読件数 3,069,495 件、衛星画像を用いた PV 判読による補完件数 631,529 件、計 3,701,024 件となった。

### 3.3 FIT 事業計画認定情報を活用した PV 導入場所の特定

#### 1) FIT 事業計画認定情報から PV 導入場所を特定する上での課題

##### ①現状の把握

経済産業省資源エネルギー庁がインターネットで公開している事業計画認定情報公表用ウェブサイト (<https://www.fit-portal.go.jp/PublicInfo>) から、事前にダウンロードした事業計画認定情報（以下 FIT 情報という）の CSV データファイルをもとに、商用のアドレスマッチングサービス（住所から緯度・経度等の座標情報へ変換を行うサービス）を活用して緯度・経度に変換し、GIS に取り込んで地図上に展開した。

変換する際に、マッチングした位置情報のレベルを（都道府県、市町村、大字、番地、号、枝番）の 6 段階で特定した。地図上に転換した FIT 情報をこの 6 段階で色分けして表示した。




図 3.3-1 FIT 事業計画認定情報分布図（アドレスマッチングレベル表示）

その結果、場所が特定できると考えられる“号レベル”のマッチングが全体の 1 割強と少ないことが判明した。全体の 50%以上が“大字レベル”以下の位置情報としては大きな誤差を含む情報に該当し、PV 導入場所の特定を行うに必要な位置精度を有しておらず、基本的に使用できないと判断した。

## ② PV 導入場所を特定する上での課題

FIT 事業計画認定情報を活用した PV 導入場所特定の目的は、AI による PV 導入場所の対象外である野立ての PV の位置情報（緯度・経度）を特定することにある。

しかし、FIT 事業計画認定情報に記載されている事業者の住所から GIS の地図上に展開可能な緯度・経度等の位置座標にすべて変換することは現状では難しい。

その要因は、野立て PV など FIT 認定情報の多くは地番表記で登録されており、それに対応したアドレス・マッチングテーブルが一般のアドレスマッチングサービスに存在しないことにある。逆に住居表示で号レベルまで記載されている建物 PV は正しい場所が得られることを確認している。



図 3.3-2 正しく取得できた建物 PV の FIT 認定情報

## 2) FIT 事業計画認定情報を用いた代替案

### ①現状の FIT 認定情報を活用した代替案

アドレスマッチングのレベルに依存することなく、FIT 事業計画認定情報の地域性を俯瞰的に把握する方法を検討した。代替案として、市区町村別に各 FIT 事業認定情報の太陽電池の出力容量 (kW) を集計して容量別に地図上で段彩表現を行えるよう地図調整を行った。市区町村レベルまでデータを集約することによって、約 100% の FIT 認定情報を活かすことができる。






図 3.3-3 市区町村別 FIT 太陽電池の出力容量総計 (kW)

## ②AI 解析による野立て PV 導入状況の把握

本業務における FIT 情報活用の目的は、本業務で把握する建物 PV 以外の事業用 PV、主に野立て PV の導入状況の把握にある。建物 PV 同様に AI 解析を用いて PV 導入状況を把握することが最も現実的な手法であると考えられる。さらに建物 PV と比較して、ターゲットとする PV の面積が大きいいため、位置の特定が目的であれば使用する画像も 1m で十分解析が可能であり、全国の解析も短時間で実施することが可能である。但し、パネルの形状を把握する際には、パネル全体で一つのポリゴンを形成するか、パネル一つ一つにそれぞれポリゴンを形成するかの判断が難しいこと、地域によっては位置特性も大きく異なることが課題となる。地域ごとに PV の取得方法を変える、入力画像のサイズを変え一度に判読できる PV の範囲を変えるなどの方策が必要になる。




図 3.3-4 AI 解析を用いた野立て PV 導入状況把握（恵那市）

### 3.4 PV 導入場所の可視化 (2.1~2.3 の統合)

PV 導入場所の可視化に関しては、“3.1 航空画像を用いた AI 分析による導入場所の特定”、“3.2 衛星画像を用いた AI 分析による導入場所の特定”の工程において、すでに可視化を実施している。ここでは PV 導入場所の中で特徴的な箇所において可視化を行うとともに、統計情報を用いて全国的な PV 導入状況データの可視化を行う。但し、分析結果は AI による予測値である。

まずは、AI 解析による PV 導入場所の予測結果をすべて、GIS に取り込み可視化した。




図 3.4-1 AI 解析による PV 導入場所の可視化

次に、XYZ タイル、zoom level 15 (約 1 km 四方) のメッシュ図郭の中で PV 導入箇所が最も多い地域 (兵庫県神戸市) を可視化した。



図 3.4-2 PV 数をもっとも多い地域 (ズームレベル 15)

次に、最も標高が高い PV を可視化した。標高 3,080m の槍ヶ岳山荘の屋根上に設置されている PV である。



図 3.4-3 最も標高が高い PV

次は、全国で最も建物 PV 導入数が多い、岡山県倉敷市の PV 設置状況を可視化した。




図 3.4-4 最も建物 PV 導入数が多い倉敷市の PV 設置状況

さらに、行政界ポリゴンと市区町村別統計情報（人口）を用いた PV 導入状況の市区町村別の分析結果を可視化した。行政面積は、GIS を用いて行政界ポリゴンから算出した数値を使用し、統計情報（人口）は、“令和 3 年 1 月 1 日住民基本台帳年齢階級別人口（市区町村別）（総計）”を使用した。

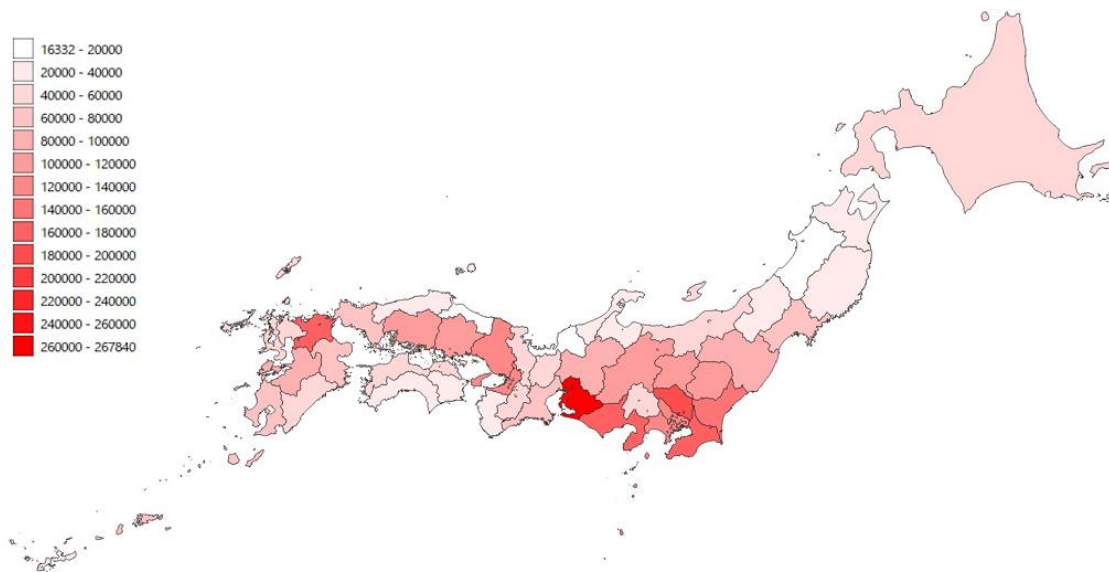


図 3.4-5 都道県別 PV 設置数




図 3.4-6 市区町村別 PV 設置数




図 3.4-7 市区町村別 1k㎡あたりのPV設置数




図 3.4-8 市区町村別 1人あたりのPV設置数




図 3.4-9 市区町村別 1世帯あたりのPV設置数

以上、AI解析によるPV導入場所をGISに取り込み、様々な視点から可視化を行った。

### 3.5 AI 判読結果の把握可能精度・網羅率の検証

本項の説明に入る前に、機械学習における一般的評価手法について解説する。機械学習の評価指標として主に正解率 (Accuracy)、適合率 (Precision, 精度)、再現率 (Recall) がある。これら評価指標の説明に入る前に、混同行列について解説する。混同行列とは、2 値分類問題において、予測と実際の分類を行列にまとめたものである。

表 3.5-1 混同行列

		予測	
		Positive (正と予測)	Negative (負と予測)
実際	Positive(正)	TP (True Positive)	FN (False Positive)
	Negative (負)	FP (False Positive)	TN(True Negative)

TP (True Positive、真陽性) : 予測値を正として、その予測が正しい場合

TN (True Negative、真陰性) : 予測値を負として、その予測が正しい場合

FP (False Positive、偽陽性) : 予測値を正として、その予測が誤りの場合

FN (False Negative、偽陰性) : 予測値を負として、その予測が誤りの場合

#### ①正解率

正解率 (Accuracy) は、予測結果全体がどれくらい真の値と一致しているかを表す指標で以下の式で求められる。

$$\text{正解率 (Accuracy)} = \frac{TP + TN}{TP + FP + TN + FN}$$

AI 解析結果は TN 判定しておらず正しく評価することができないため、本業務では正解率は使用しない。

#### ②適合率

適合率 (Precision) は、正と判定した結果のうち、実際に真の値と一致しているかを表す指標である。

$$\text{適合率 (Precision, 精度)} = \frac{TP}{TP + FP}$$

判定したすべての結果に対する評価には適しているが、どれだけ偽陰性の予測を出しても適合率には反映されない。また、本業務において適合率の評価を行う上では、すべての判定結果を (TP+FP) として扱う。



## ②再現率

再現率 (Recall) は、実際に正であるものの中から、どれだけ正と予測できたかを表す指標で、網羅率を意味する指標である。

$$\text{再現性 (Recall, [網羅率])} = \frac{TP}{TP + FN}$$

適合率と対照的な指標であり、どれだけ偽陽性判定をしても網羅率には反映されない。つまり、どれだけ誤認識しても網羅率が下がることはない。また、本業務における再現率 (以下、網羅率) は、実際の建物 PV のうち、どれだけ抽出できたかを評価する。

以上、AI 解析結果は適合率と網羅率を用いて評価することとした。

### (1) 網羅率・適合率の検証方法

屋根上 PV は、実際に現場を確認する以外に真値を確認する方法がなく、また、画像と現況で経年変化がある場合は、AI 解析の結果を正しく評価することができない。従って、AI 解析元となる画像データの撮影時点において、画像を目視判読した結果と AI 解析結果を照合し検証・評価を行う。

また、AI 解析は網羅率 (再現率: 検出されるべき PV 設置建物のうち、検出された PV 設置建物の割合) を優先して AI をチューニングしており、網羅率が高くなるトレードオフとして、建物以外の物体を誤検出し、精度 (適合率: 検出した結果のうち、正の割合) 低下を招く傾向にある。ただし、AI 解析は建物外の誤検出データを建物データ (ポリゴン境界) によって除外する前提で行っていることから、適合率の検証においても、建物上で検出したすべての結果に対してのみ実施することとした。

以下のとおり GIS を用いて精度及び網羅率の検証作業を実施した。工程の手順上、網羅率検証、精度検証の順で報告を行う。

### 1) 鮮度・検出量優先地域 (主に都市近郊・郊外)

- ① 2020 年以降の CDS 撮影範囲を対象に、Web メルカトル XYZTile 仕様のズームレベル 15 (約 1 km 四方) のメッシュ単位で、PV 判読結果の検出ポイント数を集計する。そのうち検出数が多い上位 10 メッシュを抽出し、さらにオルソ画像と建物データとの経年変化、位置ズレが少ない 5 地域を選定する。



図 3.5-1 検証地域の選定①

- ② 選定したメッシュ領域が 1k m<sup>2</sup>以上になるよう、上下左右 100m 程度範囲を拡大して領域を再設定し、この領域に重なる建物ポリゴンおよび AI 解析による PV 判読ポイントを抽出する。
- ③ CDS オルソ画像を背景に目視で屋根上 PV を判読し、②で抽出した建物ポリゴンの属性に“PV”フラグを付与する。この時オルソと建物ポリゴンに位置ズレや経年変化がある場合は適宜建物を移動、追加・削除等の修正を行う。また、PV 設置が目視で判断できない場合は除外フラグを付与し、当該建物および当該建物上で PV 抽出した結果を評価の対象から除外する。実際には航空画像と建物ポリゴンの更新時点の違い（航空画像で確認された建物が建物ポリゴンに存在しない）や、オルソとの位置ズレが想定よりも大きく、地域によっては位置ズレの修正のためにすべての建物ポリゴンの位置を調整するなどの対応が必要になった。
- ④ 建物ポリゴンの境界内に PV 判読ポイントが含まれているかを空間演算で判定し、含まれている場合は、“predict”フラグを付与する。
- ⑤ 上記③、および④で付与した建物ポリゴンの属性情報から、“PV”フラグが立っているすべての建物ポリゴンのうち、“predict”フラグが立っている建物ポリゴンの割合（網羅率）を算出する。
- ⑥ 次に、PV 判読ポイントのうち、建物ポリゴン領域に含まれるポイントに対して、

“on\_bld” フラグ付与する。さらに“PV” フラグがたっている建物ポリゴン領域に含まれるポイントに対して、“on\_PV\_bld” フラグを付与する。

- ⑦ on\_bld” フラグが立っているすべての PV 判読ポイントを対象に、“on\_PV\_bld” が立っているポイントの割合（適合率）を算出する。

## 2) 耕地、中山間、山地

1)では、新しい航空画像と建物ポリゴンを用いて、なるべく多くの建物を対象に、AI 解析による PV 検出結果の評価を行うこととしたが、一方で人口比率は圧倒的に小さいが国土の大部分は耕地、中山間地、山地に属している。従ってこれら地域を対象とした検証を以下の工程で実施する。

- ① 都市近郊地、郊外地を対象に、選出した地域とは性質が異なる地域を無作為に 5 地域抜粋する。この時、1)と比較して対象となる建物数が圧倒的に少ないため、1 地域あたりの検証範囲を拡大し Web メルカトル XYZTile ズームレベル 15（約 2 km 四方）のメッシュ領域を対象とする。



図 3.5-2 検証地域の選定②

- ③ 地域的に航空画像や建物データの更新が滞っていることもあり、既存の建物ポリゴンを活用せず、①の範囲内において、航空画像と衛星画像から目視で PV 判読し、PV 建物ポリゴンを手動で入力、且つ“PV” フラグ属性を付与する。また、PV 設置が目視で判断できない場合は除外フラグを付与し、当該建物および当該建物上で PV 抽出した結果を評価の対象から除外する。

- ④ 1) 鮮度・検出量優先地域（主に都市近郊・郊外）の④～⑦の工程と同様に、網羅率、適合率の検証を実施する。



図 3.5-3 網羅率検証のポイント

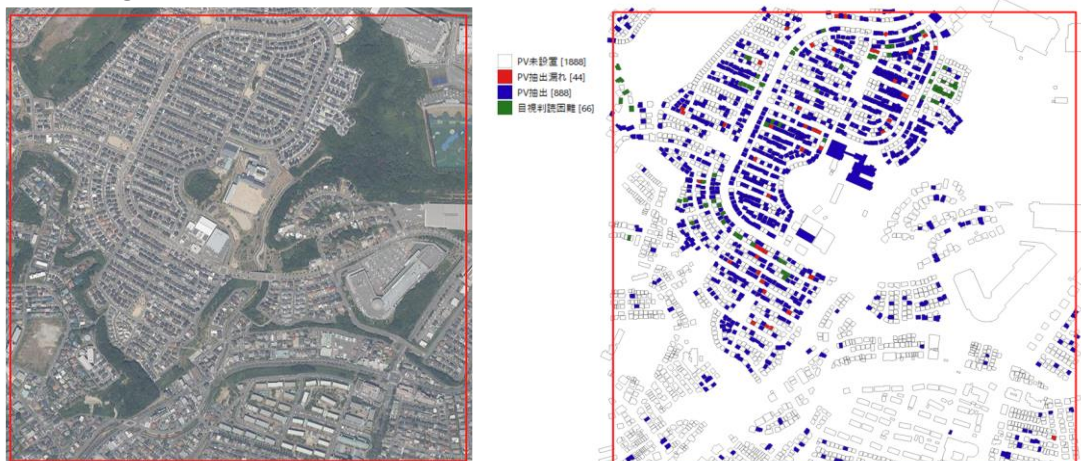
## (2) 網羅率の検証

“(1) 網羅率・適合率の検証方法”に基づき実施した網羅率検証結果を以下に示す。網羅率算出は以下のとおり算出した。

$$\text{網羅率} = \text{再現率 (Recall)} = \text{TP} \div (\text{TP} + \text{FN})$$

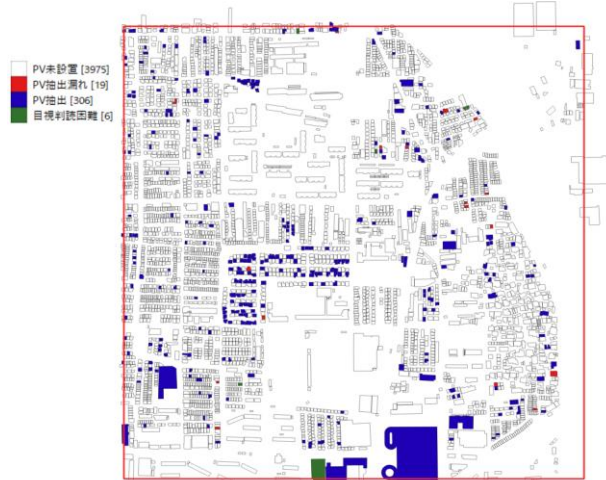
$$\text{網羅率 (再現率)} = \text{PV フラグ且つ PV 判読フラグ付き建物数} / \text{PV フラグ付き建物数}$$

### 検証地域① (神戸市)




$$\text{網羅率} = \text{建物 PV 抽出棟数 (888)} \div \text{建物 PV 棟数 (932)} = 95.28\%$$

検証地域②（大阪市）



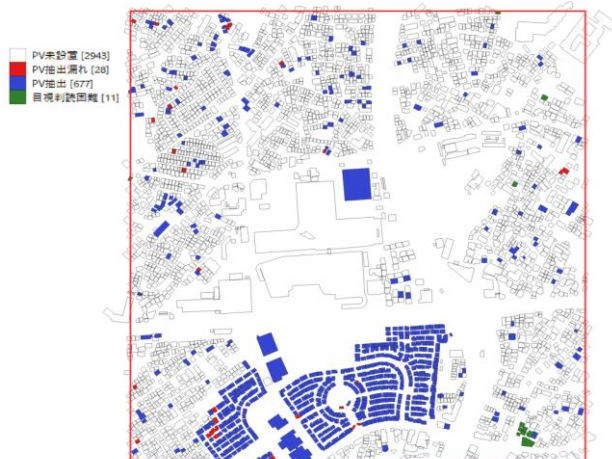
網羅率 = 建物 PV 抽出棟数 (306) ÷ 建物 PV 棟数 (325) = 94.15%

検証地域③（名古屋市）



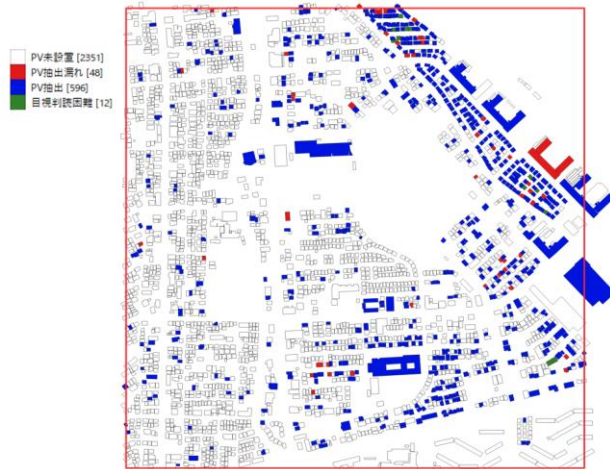
網羅率 = 建物 PV 抽出棟数 (433) ÷ 建物 PV 棟数 (441) = 98.19%

検証地域④（神奈川県藤沢市）




網羅率 = 建物 PV 抽出棟数 (677) ÷ 建物 PV 棟数 (705) = 96.03%

検証地域⑤（埼玉県吉川市）




網羅率 = 建物 PV 抽出棟数 (596) ÷ 建物 PV 棟数 (644) = 92.55%

検証地域⑥（北海道伊達市）



網羅率 = 建物 PV 抽出棟数 (87) ÷ 建物 PV 棟数 (89) = 97.75%

検証地域⑦（岩手県雫石町）




網羅率 = 建物 PV 抽出棟数 (49) ÷ 建物 PV 棟数 (51) = 96.08%

検証地域⑧（群馬県東吾妻町）




PV抽出漏れ [1]  
PV抽出 [33]




網羅率 = 建物 PV 抽出棟数 (33) ÷ 建物 PV 棟数 (34) = 97.06%

検証地域⑨（山口県宇部市）



PV抽出漏れ [1]  
PV抽出 [18]




網羅率 = 建物 PV 抽出棟数 (18) ÷ 建物 PV 棟数 (19) = 94.74%

検証地域⑩（鹿児島県隼人町）



pv抽出漏れ [12]  
PV抽出 [342]



網羅率 = 建物 PV 抽出棟数 (342) ÷ 建物 PV 棟数 (354) = 96.61%

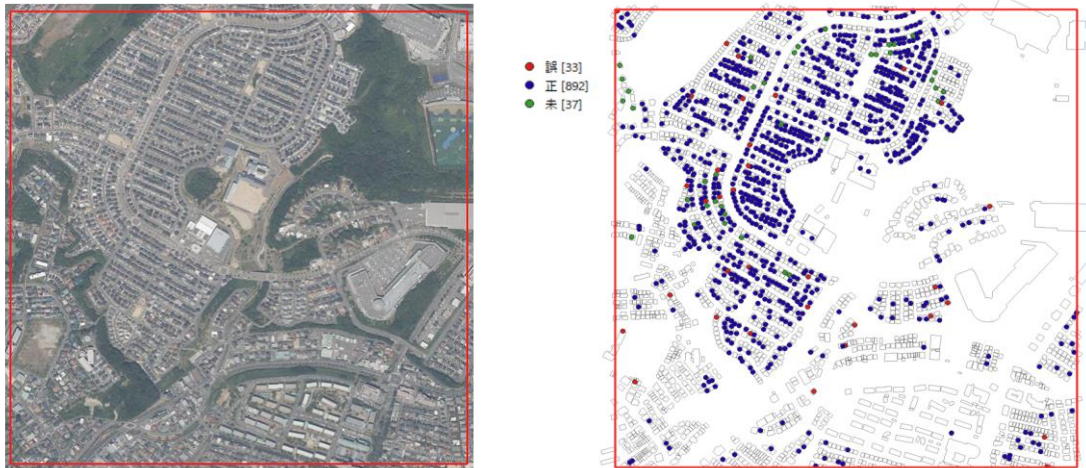
$$\text{Total 網羅率} = \text{総建物 PV 抽出棟数 (3,428)} \div \text{総建物 PV 棟数 (3,593)} = 95.41\%$$

### (3) 適合率の検証

“(1) 網羅率・適合率の検証方法”に基づき実施した精度検証結果を以下に示す。精度算出は以下のとおり算出した。

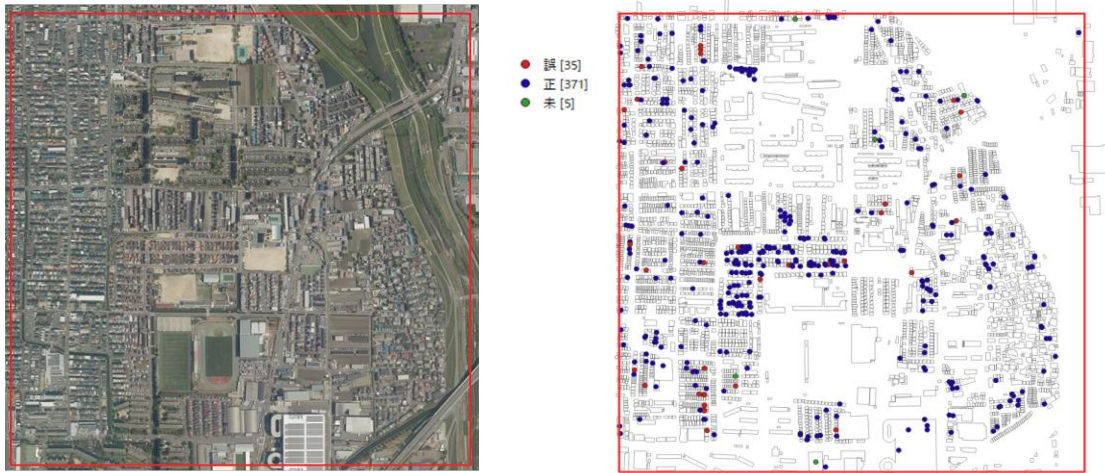
$$\begin{aligned} \text{適合率 (Precision)} &= \text{TP} \div (\text{TP} + \text{FP}) \\ \text{精度 (適合率)} &= \text{PV フラグ付き建物境界内のすべての PV 検出数} \\ &\div \text{建物境界内のすべての PV 検出数} \end{aligned}$$

#### 検証地域① (神戸市)



$$\text{適合率} = \text{PV フラグ付き建物境界内のすべての PV 検出数 (892)} \div \text{建物境界内のすべての PV 検出数 (925)} = 96.43\%$$

#### 検証地域② (大阪市)



$$\text{適合率} = \text{PV フラグ付き建物境界内のすべての PV 検出数 (371)} \div \text{建物境界内のすべての PV 検出数 (406)} = 91.38\%$$

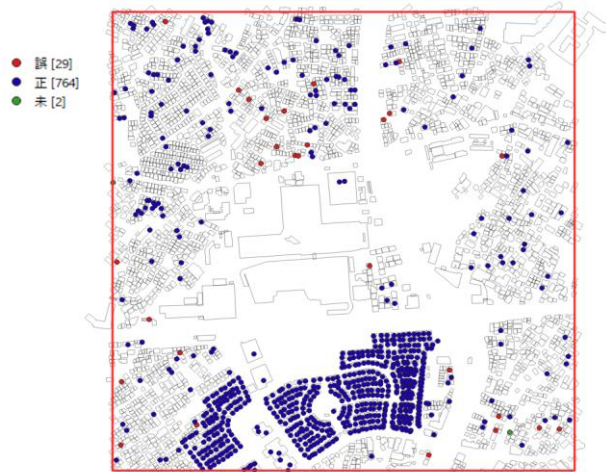


検証地域③（名古屋市）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (472) ÷ 建物境界内のすべての PV 検出数 (478) = 98.74%

検証地域④（神奈川県藤沢市）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (764) ÷ 建物境界内のすべての PV 検出数 (793) = 96.34%

検証地域⑤（埼玉県吉川町）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (616) ÷ 建物境界内のすべての PV 検出数 (635) = 97.01%

検証地域⑥（北海道伊達市）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (90) ÷ 建物境界内のすべての PV 検出数 (94) = 95.74%

検証地域⑦（岩手県雫石町）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (55) ÷ 建物境界内のすべての PV 検出数 (55) = 100%

検証地域⑧（群馬県東吾妻町）




適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (33) ÷ 建物境界内のすべての PV 検出数 (38) = 86.84%

### 検証地域⑨（山口県宇部市）



適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (19) ÷ 建物境界内のすべての PV 検出数 (20) = 95.00%

### 検証地域⑩（鹿児島県隼人町）



適合率 = PV フラグ付き建物境界内のすべての PV 検出数 (374) ÷ 建物境界内のすべての PV 検出数 (383) = 97.65%

Total 精度 (適合率) = PV フラグ付き建物境界内のすべての PV 検出数 (3,686)  
÷ 建物境界内のすべての PV 検出数 (3,827) = 96.32%

参考に、建物外の検出数を含めた適合率は表 3.5-2 のとおりであり、上記結果より 1.3 ポイント下回る。中山間地、山地では建物 PV 以外の誤検出が増える傾向にあるが、使用した航空画像の鮮明度が著しく低いことと、衛星画像を用いた同等地域の教師データおよび学習を行っていないことに起因している。但し、トータルとしては微量で大きく影響することはない。今後、衛星画像の学習強化に伴い、同等地域における精度向上が図れると考えられる。

表 3.5-2 すべての検出点における適合率

地域	対象面積	正	総検出数	適合率
神戸	約1km <sup>2</sup>	892	928	96.12%
大阪	約1km <sup>2</sup>	371	416	89.18%
名古屋	約1km <sup>2</sup>	472	484	97.52%
藤沢	約1km <sup>2</sup>	764	795	96.10%
吉川	約1km <sup>2</sup>	616	638	96.55%
伊達	約4km <sup>2</sup>	90	97	92.78%
栗石	約4km <sup>2</sup>	55	63	87.30%
東吾妻	約4km <sup>2</sup>	33	41	80.49%
宇部	約4km <sup>2</sup>	18	22	81.82%
隼人	約4km <sup>2</sup>	374	394	94.92%
<b>トータル</b>	<b>約25km<sup>2</sup></b>	<b>3,685</b>	<b>3,878</b>	<b>95.02%</b>

#### (4) 課題

本業務では、適合性を犠牲にして網羅率を向上させる手法をとった。その技術的担保として、誤検出したデータのうち、建物以外を検出したデータについては建物ポリゴンデータを用いて、取り除くことが可能であるという仮説が前提にあった。しかし、航空画像、衛星画像とも基準となる建物情報との位置ズレ箇所が想定より多く、建物ポリゴンデータに関してもポリゴン外形が正しくないものが多く、現況に即していないデータも数多くあることが判明した。このことはフィルタリングの機械処理が困難となるだけでなく、航空画像や衛星画像から正しく抽出されたデータを建物情報と紐づけることが困難となる要因となる。つまり、位置的、時間的整合を図るための手法を確立できなければ、正しい検証は困難であり、今後の精度向上において課題となる。

### 3.6 PVパネル形状の抽出と設備容量の把握可能性の検証

#### 1) 使用するPV形状抽出システムの特徴

PVパネル形状の抽出には、オービタルネット社製「Geo Tracer II」を使用した。Geo Tracer IIはディープラーニングのインスタンス・セグメンテーションというディープラーニング画像認識技術と位置情報技術を組み合わせたツールである。

ベースとなっているインスタンス・セグメンテーションは、認識スピードこそ物体検出に劣るが、物体検出同様に物体のラベルと画像上の位置情報を認識することに加え、検出した各々の物体（例えばPV）に対して、ピクセル単位で境界（PV とその他）を分割することが可能な高度な技術である。

同じような画像認識技術にセマンティック・セグメンテーションがあるが、これは画像全体に対して、ピクセル単位で境界（PV とその他）を分割する技術で、物体各々の識別はできない。

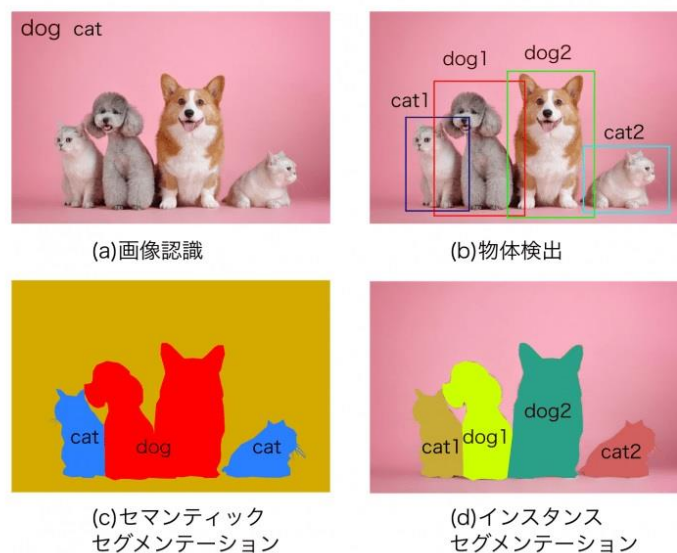


図 3.6-1 ディープラーニング画像認識技術

出典：CVML エキスパートガイド HP

#### 2) インスタンス・セグメンテーション技術を使用するメリット

インスタンス・セグメンテーションは物体検出技術とセマンティック・セグメンテーションを組み合わせた良いとこ取りの技術といえる。Geo Tracer IIは、インスタンス・セグメンテーションで抽出したインスタンスに位置情報を付与し、境界判定したピクセルをポリゴン領域としてベクトルデータ化して出力できることが特徴である。

このインスタンス・セグメンテーションベースのツールを本業務に用いる利点は、建物上の複数のPVのパネル形状を一塊として取得し、マルチポリゴンとして管理できる点である。GISに取り込み建物単位で面積を算出することが容易になる。

### (1) 特定エリアにおける PV パネル形状・面積の抽出

PV 形状抽出システムの特徴と課題を把握したうえで、特定エリアにおける PV パネル形状・面積の抽出を実施した。解析する画像は XYZTiles 仕様でズームレベル 20 相当の解像度が必要となる（詳しくは次項で解説する）。本業務で使用する GEOSPACE CDS では、23 区、大阪市、名古屋市の範囲が該当する。

そこで、大阪市、名古屋市において、都市近郊でビル、工場、量販店や多様な屋根形状の家屋が存在する地域を以下のとおり選定した。

(大阪市南部) 阿倍野区、東住吉区、平野区、天王寺区、生野区、東成区、住吉区

合計行政面積約 58k m<sup>2</sup>

(名古屋市南部) 緑区、天白区

合計行政面積約 59k m<sup>2</sup>




図 3.6-2 対象行政 (左：大阪市、右名古屋市)

上記対象地域においてディープラーニングのインスタンス・セグメンテーション (検出したオブジェクト単位で物体の境界をピクセル単位で判定する技術) を用いて、屋根上 PV の境界をトレース、形状を抽出した上で、GIS 上で面積算出を行った。

具体的には Geo Tracer II による処理において、抽出した建物単位の PV のパネルにユニーク id が付番されており、これを GIS に取り込み、id をもとにマルチポリゴン化することで、同一建物上の複数のパネルが図形として一体化される。さらに GIS において建物単位の面積集計が可能になる。

図 3.6-3 は建物 PV 単位で抽出したインスタンスのイメージである。物体検出 (建物 PV 単位で切り出された画像) とセグメンテーション (切り出された画像の PV 領域をポリゴン化) を同時で実施されていることがわかる。

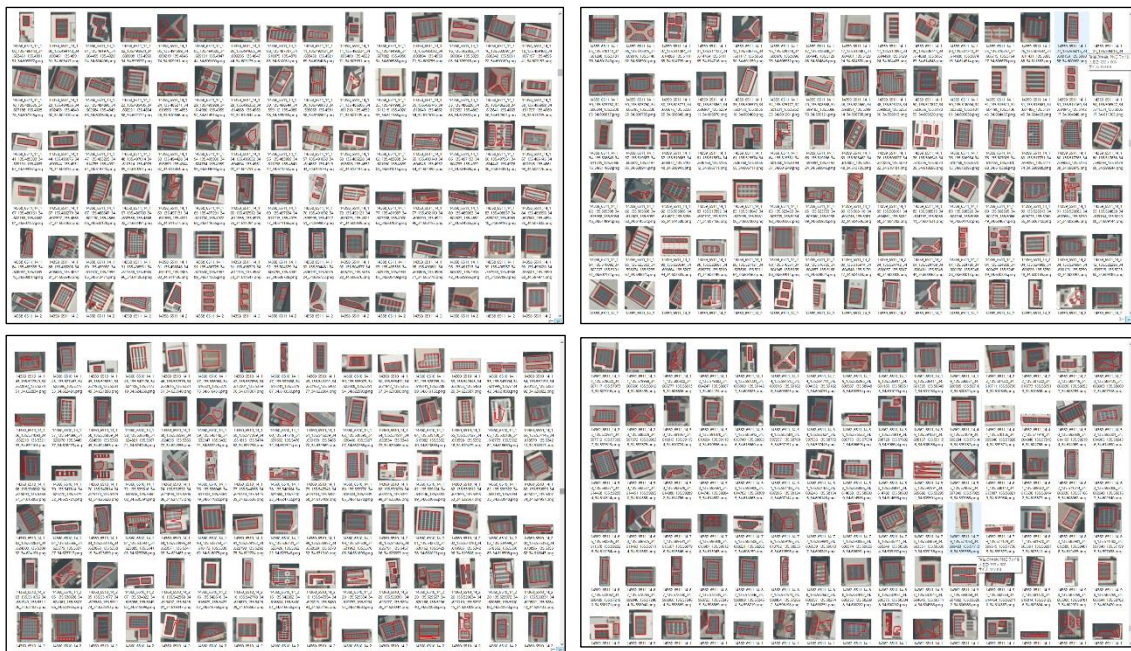


図 3.6-3 PV 形状の抽出イメージ

これまでの課題として建物単位の面積算出において、PV が複数の画像にまたがる場合、その接合部分でPV が分断され、それぞれがポリゴン化されることがあげられる。これを解消するために、入力画像を詳細画像（1028px×1028px）、広域画像（2048px×2048px）の2種類作成し、それぞれにおいて、Geo Tracer II によるインスタンス・セグメンテーションを実施した。詳細画像で抽出したPV ポリゴンから画像の接合領域（メッシュ線にバッファを加えた領域）に重なるポリゴンを除外し、広域画像で抽出したポリゴン（差分）で置き換える手法をとった。それでも広域画像の接続部で分断されるPV が存在するが、それらは手動で接合を行った。今後、手動で行っている工程を自動化するなどの検討が必要である。



大阪市南部抽出範囲 84.86k m<sup>2</sup>

名古屋市南部抽出範囲 84.92k m<sup>2</sup>

図 3.6-4 PV パネル形状の抽出結果



抽出結果を GIS に取り込み、同じ建物 ID の地物のマルチポリゴン化を図り、さらに面積を属性に付与した。整備した PV 形状データを可視化した結果を以下に示す。




図 3.6-5 PV パネル形状の面積算出①




図 3.6-6 PV パネル形状の面積算出②

## (2) 設備容量の推計方法の検討

設備容量の推計に当たっては、5.5 項において設定した設置係数を用いる。

## (3) 実績データによる検証及び課題・解決策の検討

### 1) 実績データによる検証

本工程において整備した、PV 形状データの検証方法について記載する。

「PV 導入場所の特定」と同様、適合率、網羅率の検証も必要であるが、ここでは尺度を変えて PV 形状の精度について検討し、検証していく。

形状自体の精度を定量的に示すのは次の点から容易ではない。例えば真値との面積を比較するという方法があるが、真値を定義することは容易ではなく、さらに、真値が存在すると仮定して、AI 解析により形状取得した面積が真値と同等であった場合も、建物上の PV ではないものを形状取得し、偶然面積が真値と等しくなるケースである可能性があるため、精度が高いとは言えない。

そこで、解決手法として IoU (Intersection over Union) を使用した精度検証を行うこととした。IoU が 1 で図形の完全一致、0 でどちらかの図形がないか重ならないとなる。

具体的には、サンプリングした PV 形状データと、既知データ (建物上のソーラーパネル形状) の重なり度合を、IoU を用いて数値化し、平均値及び標準偏差を求める。IoU は図形の一致率と言い換えることができ、データの特性を定量的に把握することが可能と考える。




図 3.6-7 IoU (Intersection over Union) の概念

実際には真値としての既知データ (建物上のソーラーパネル形状) は存在していないので、サンプリングした PV 形状データから、同建物の PV を目視で判読し、ソーラーパネルの形状を GIS 上で手動トレースして代替える。

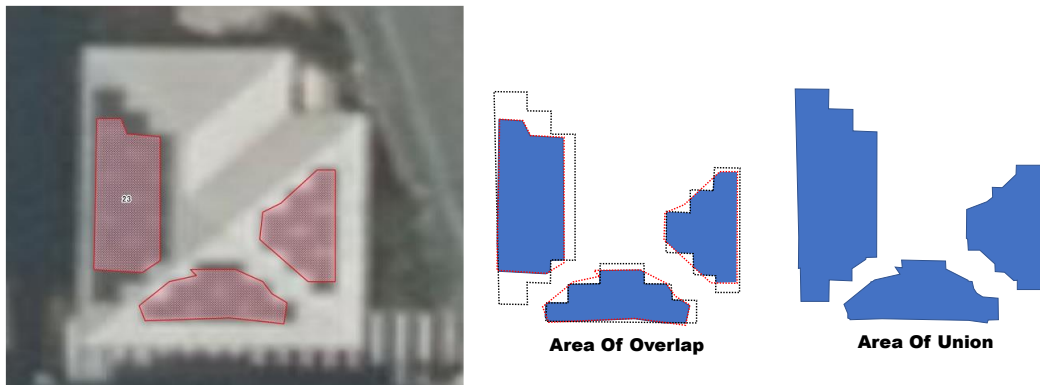






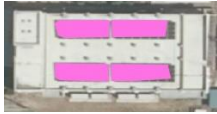


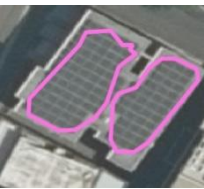










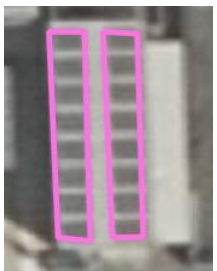
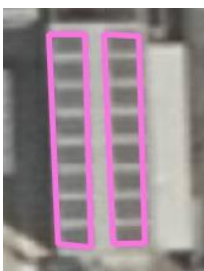
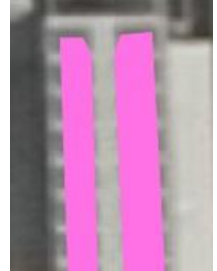





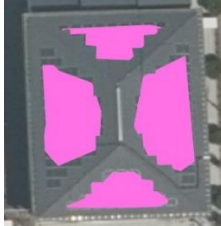
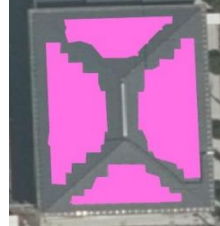




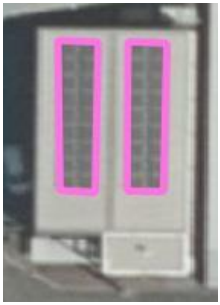



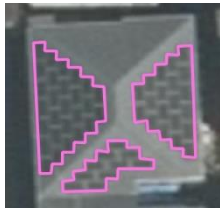



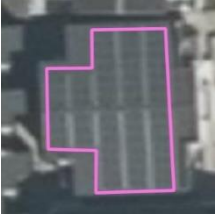
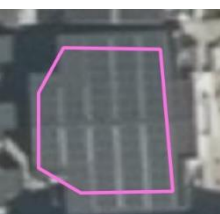
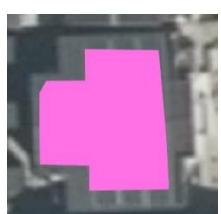
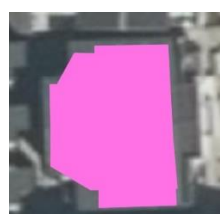




図 3.6-8 IoUによるPVの重なり度合の抽出イメージ


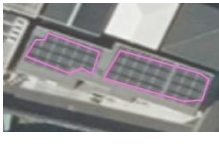


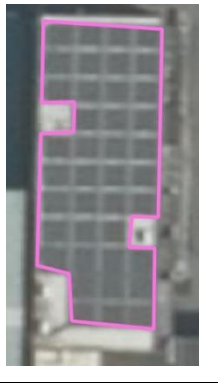
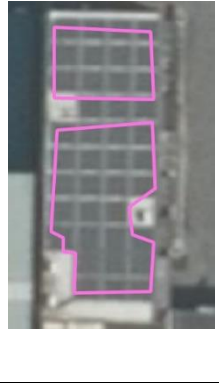

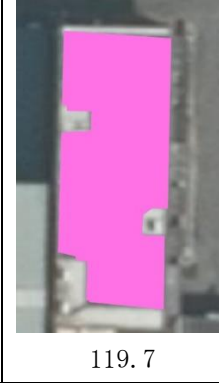
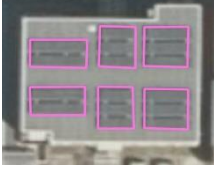











まず、大阪市南部のPV形状抽出結果において、20箇所へのサンプリングを行い、PVをトレースしたものと、セグメンテーションによる予測結果(predict)を元に、Overlap、Unionの面積を求めIoUを算出した。

表 3.6-1 大阪市南部検証結果 (IoUの算定)

id	PV	Predict	Overlap	Union	IoU
1			 101.3	 132.9	0.7622
2			 112.7	 149.5	0.7538
3			 121.9	 162.1	0.7520

4					0.7295
			141.3	193.7	
5					0.8125
			159	195.7	
6					0.8082
			151.3	187.2	
7					0.8605
			25.9	30.1	
8					0.7000
			22.4	32	
9					0.6341
			22.7	35.8	

10					0.7543
			306.4	406.2	
11					0.7387
			426.7	577.6	
12					0.7549
			46.2	61.2	
13					0.8235
			62.5	75.9	
14					0.7806
			64.4	82.5	
15					0.8506
			712	837.1	

16			 72.4	 88.3	0.8199
17			 90.9	 119.7	0.7594
18			 78.1	 101.7	0.7679
19			 91.1	 108.3	0.8412
20			 95.3	 115.6	0.8244

20 件の IoU から、平均値、標準偏差を算出した。

平均値 : 0.7764、 標準偏差 : 0.05377

この結果は、0.7764 の  $\pm 0.05377$  の中に大部分のデータが存在していることを意味する。さらに、正規分布図を作成し可視化した。

平均値	0.7764
標準偏差	0.0537745

x	f(x)
0.6341	0.2234
0.7000	2.7033
0.7295	5.0691
0.7387	5.8051
0.7520	6.6928
0.7538	6.7936
0.7543	6.8179
0.7549	6.8485
0.7594	7.0567
0.7622	7.1652
0.7679	7.3274
0.7806	7.3963
0.8082	6.2276
0.8125	5.9252
0.8199	5.3469
0.8235	5.0601
0.8244	4.9824
0.8412	3.5917
0.8506	2.8676
0.8605	2.1867








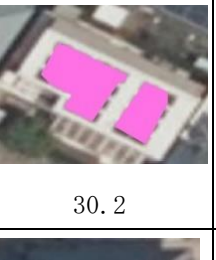
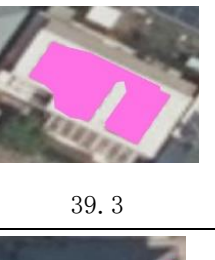
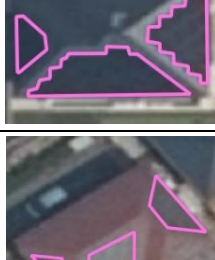

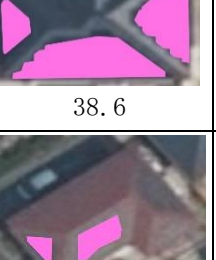

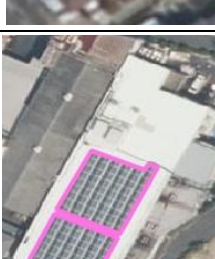
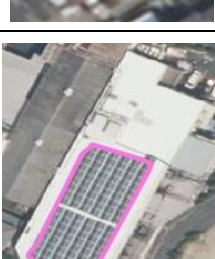

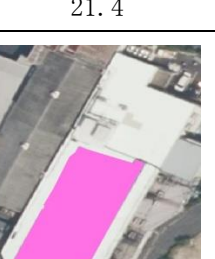














図 3.6-9 正規分布





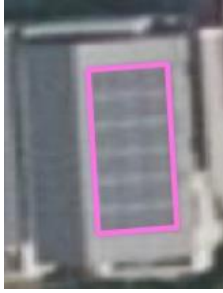





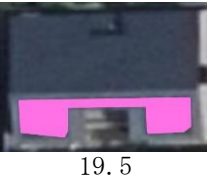
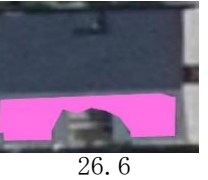
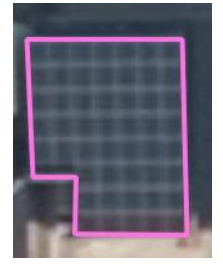



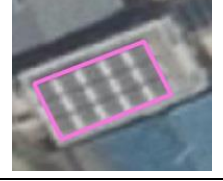






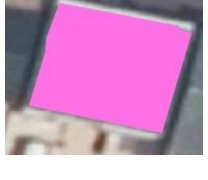




続いて、名古屋市南部のPV形状抽出結果において、20箇所のサンプリングを行い、PVをトレースしたものと、セグメンテーションによる予測結果(predict)を元に、Overlap、Unionの面積を求めIoUを算出した。

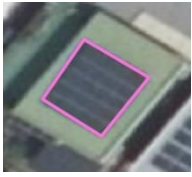
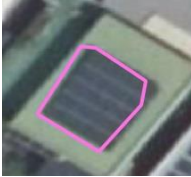










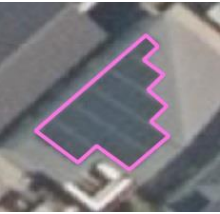



表 3.6-2 名古屋市南部検証結果 (IoUの算定)

id	PV	predict	Overlap (m <sup>2</sup> )	Union (m <sup>2</sup> )	IoU
1			 44.4	 57.5	0.7722
2			 12.3	 17	0.7235

3			 3650.5	 4170	0.8754
4			 30.2	 39.3	0.7684
5			 38.6	 50.5	0.7644
6			 9.3	 21.4	0.4346
7			 373.4	 412	0.9063
8			 26.6	 37.2	0.7151
9			 339.5	 425.2	0.7984



10			 14.8	 25.3	0.5850
11			 22.1	 25.2	0.8770
12			 19.5	 26.6	0.7331
13			 46.6	 66.7	0.6987
14			 22.5		0.7840
15			 47.8	 55.4	0.8628
16			 6.5	 9.3	0.6989

17			 26.3	 32.4	0.8117
18			 20.4	 23.3	0.8755
19			 32.9	 43	0.7651
20			 32.8	 37.7	0.8700

20 件の IoU から、平均値、標準偏差を算出した。

平均値 : 0.7660、 標準偏差 : 0.1088

この結果は、0.7660 の±0.1088 の中に大部分のデータが存在していることを意味する。  
さらに、この結果を正規分布図を作成し可視化した。

平均値	0.7660
標準偏差	0.1088142

x	f(x)
0.4346	0.0355
0.5850	0.9188
0.6987	3.0271
0.6989	3.0318
0.7151	3.2856
0.7235	3.3973
0.7331	3.5022
0.7644	3.6659
0.7651	3.6661
0.7684	3.6653
0.7722	3.6604
0.7840	3.6166
0.7984	3.5069
0.8117	3.3565
0.8628	2.4680
0.8700	2.3216
0.8754	2.2115
0.8755	2.2091
0.8770	2.1795
0.9063	1.5967




図 3.6-10 正規分布

大阪市南部および名古屋市南部の検証は、サンプリングした 20 箇所のデータのみの結果であるため、極端に良いデータや極端に悪いデータは、サンプリングから漏れている可能性がある。このためすべてを網羅した結果とはいえないが、PV 形状抽出結果の PV 形状の一致率を定量化・可視化し、データ特性を把握することができた。

本業務においてはパネル形状の真値がないことから、航空画像から手入力でパネル形状を作成し真値を代替えするという課題があったが、真値を持った地域において PV 形状を抽出するなど、サンプルサイズを拡大することによって、より精度の高い検証が可能と考える。

## 2) 画像に求められる要求精度と課題

高度な技術ゆえの課題もある。3.2 項で実施した「PV 導入場所の特定」は、PV が設置されている建物を抽出することが目的であったが、本項ではさらに PV のパネル形状を抽出し、その面積を算出することが目的である。「PV 導入場所の特定」で使用した画像が、PV のあるなしを識別できる解像度で良いのに対し、「PV パネル形状・面積の抽出」は、パネルの境界が識別できる地上解像度が要求される。具体的には「PV 導入場所の特定」に使用した画像が Web メルカトル XYZTiles 仕様でズームレベル 19 (地上解像度約 25cm 程度) であったが、PV パネル形状・面積の抽出」はズームレベル 20 (地上解像度約 12.5cm 程度、タイル化前の画像の解像度は 16 cm) の解像度が求められる。

この問題は AI の解析時間にも影響する。倍の解像度の画像を使用する場合、「PV 導入場所の特定」を 1 枚で処理する領域に対して、4 枚の画像処理が必要になる。加えて、画像 1 枚あたりの処理時間が物体検出の処理時間と比較してインスタンス・セグメンテーション

は4倍近く時間を要する。このことは物体検出の20倍程度の時間を要することを意味する。短期的な対策はないが、中長期的の対策をハード面、ソフト面において検討した。

#### ① ハード面

インスタンス・セグメンテーションの処理は主に Nvidia 製の GPU で計算が行われている。処理能力の高い GPU による処理能力の向上は明らかである。さらに nVlink という GPU をブリッジ接続する方法さらに処理向上が図れる。但し価格も非常に高価で 100 万円～数百万円の費用が必要である。

#### ② ソフト面

PV 形状抽出で使用している “Geo Tracer II” のインスタンス・セグメンテーション技術は、約5年前の Mask-RCNN をベースにしているが、技術革新著しい AI の世界では最新の技術と言えない。検出速度、検出精度ともに改善する余地があり、とりわけ検出速度を改善することにより、工程全体の処理速度向上につながるものと推測される。