

# AI を活用した遺跡候補地の抽出—高精度地形データと機械学習—

高田 祐一（奈良文化財研究所）  
西尾 悟（株式会社 MIERUNE）

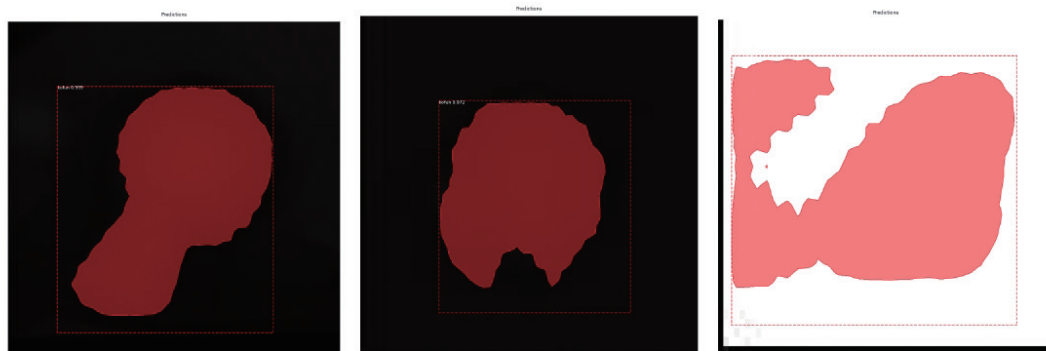
## 1. はじめに

兵庫県から公開されている高精度地形データを用いて、GIS と機械学習を用いた遺跡新発見の手法について検討した。

## 2. 高精度 DEM による機械学習

### 2.1 前方後円墳による実験

2021 年度は、機械学習用の教師データを作成した。兵庫県下の前方後円墳を対象にポリゴン GIS データを作成し、兵庫県庁から提供されている 1 m メッシュ高精度 DEM（地理標高モデル）データと組み合わせ、GIS と機械学習を用いた古墳の新発見する手法について検討した。検討では GDAL および QGIS による兵庫県全域の高精度 DEM データの前処理と、OpenCV ライブラリによるリサイズと拡張、Mask R-CNN モデルによるニューラルネットワークベースモデルの学習方法の確立を試みた。その結果、誤検出があるものの、十分な学習サンプル数があれば、DEM 画像に古墳があるかどうかを識別できる可能性が示唆された（図 1）。

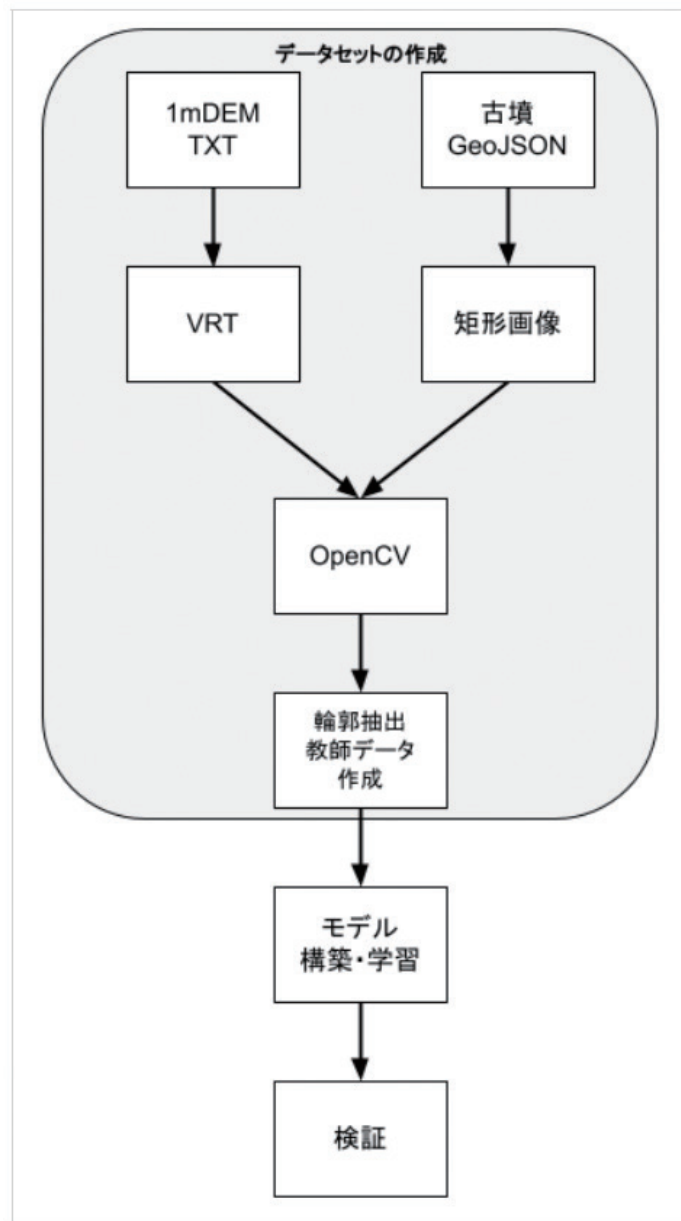


学習済みDEMでの正解/未学習DEMでの正解/未学習DEMでの不正解

（図 1）DEM での正解

## 2.2 処理フロー

処理フローについて、順に述べる（図2）。

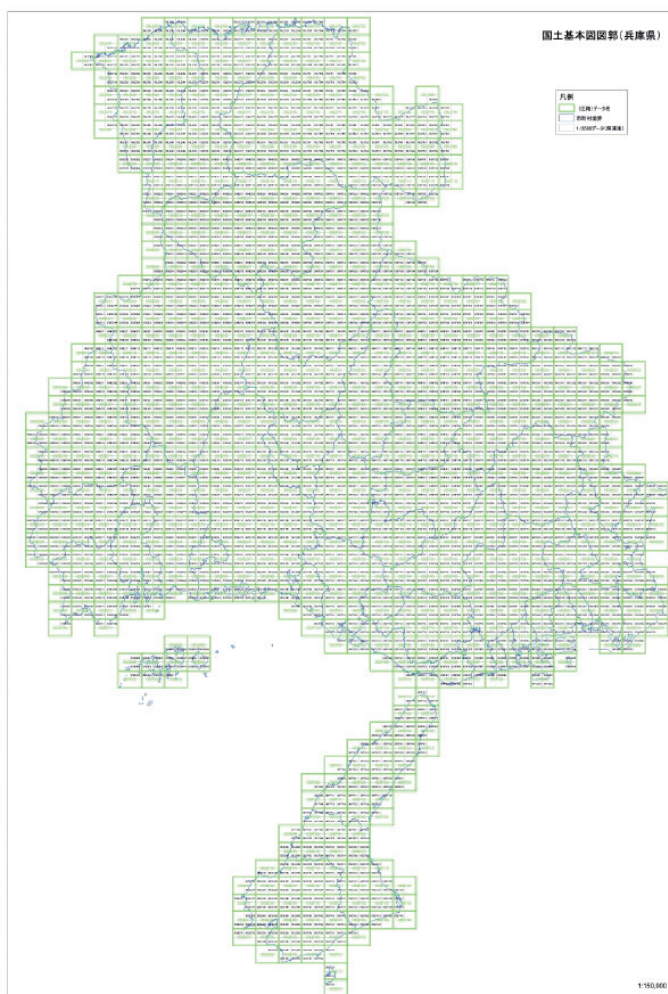


（図2）本検証での処理フロー

### 2.2.1 データセットの作成

「兵庫県\_全域数値地形図\_ポータル（2010年度～2018年度）」(<https://www.geospatial.jp/ckan/dataset/2010-2018-hyogo-geo-potal>) の TXT 形式 DEM ファイル (n=12304)（図3）および、奈良文化財研究所文化財情報研究室に作成した兵庫県下の前方後円墳 GeoJSON データ (n=52) をベースに用いた（図4）。処理を効率的に進めるため、

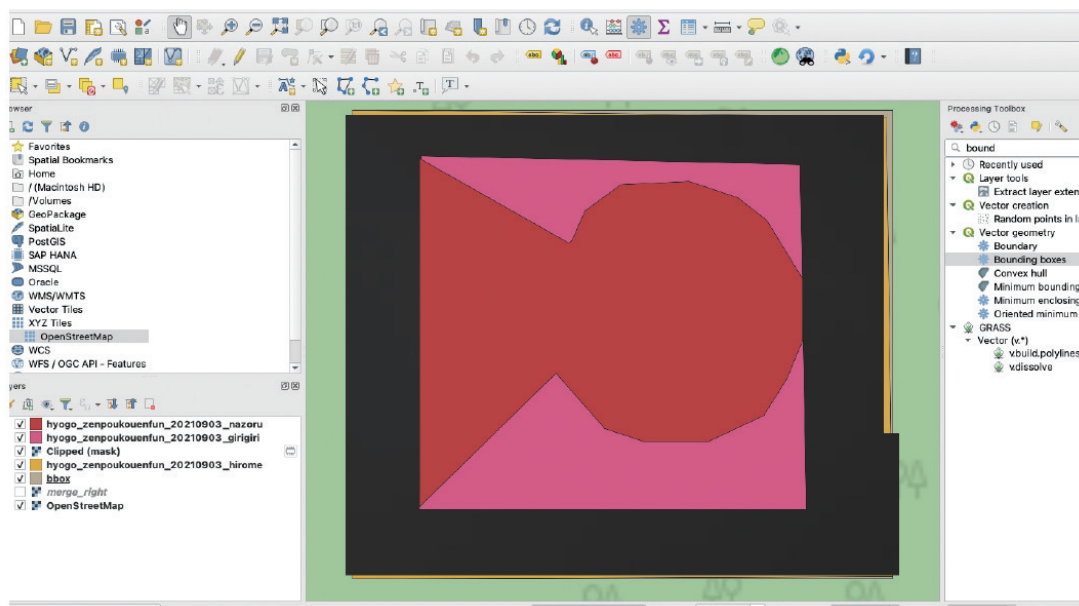
高精度 DEM データの収集と前処理を行なった。収集は、兵庫県のオープンデータサイトより高精度 DEM データを Python スクリプトによってダウンロードした。また、オープンソース GIS ライブラリの一つである GDAL を用いて投影法変換を行い、1つの VRT（仮想ラスタ）ファイルを作成した。画像処理には教師データ周辺の矩形が必要であるため、前方後円墳 GeoJSON データと組み合わせることにより、QGIS によって矩形ポリゴンを作成した。これらを組み合わせ、教師データとなる既存前方後円墳での高精度 DEM の画像を得た（図5）。機械学習を行うために、オープンソースの画像処理ライブラリである OpenCV と輪郭特定アルゴリズム（RETR\_CCOMP と CHAIN\_APPROX\_SIMPLE を組み合わせた手法）を用いて、DEM 全域画像内で特徴的な形状をもつ前方後円墳画像を抽出した（図6）。この結果、機械学習に有用な3つの古墳画像の位置が得られた。しかしモデル構築のための教師データとしてかなり少ないため、VGGannotator によるアノテーション（人力による正解入力）や明度調整といった画像補強によって学習用画像 26 枚、検証用画像 12 枚にサンプル数を増大させた。



（図3）兵庫県下 DEM データ範囲



（図4）前方後円墳 GeoJSON 例



(図5) 教師用高精度 DEM 範囲 (黒)



(図6) OpenCV による DEM 全域画像内での前方後円墳抽出結果

## 2.2.2 モデル構築

上記で作成したデータセットに適用可能なモデル学習方法を調査した結果、Mask R-CNN モデルを選定した。この Mask R-CNN は、少ないサンプル数でおおよその結果を導くことが可能で、物体検出だけでなく、物体の種類ごと（古墳 / 古墳以外）に領域を分割するインスタンスセグメンテーションも行うため、今回の前方後円墳抽出検証に合致している。また、学習は重み付けが可能な coco weights 法に基づいて実行した。

## 2.2.3 モデル学習結果

学習処理を行なった結果、Mask R-CNN モデルが学習時に使用した画像に対しては良好な結果が得られたが、初めて用いた新しい画像かつ不正解画像に対しては良好な結果が得られなかった。この理由としては、今回用いた学習用データセットの特徴が薄く、偏りがあったため、モデルがデータに過剰適合（過学習）してしまっていると思われる。このことから、


Mask R-CNN モデルでの学習では一定の方向性は見えつつも、さらに高い品質と大量の学習用データを生成し、より検出力を改善できるかの検証が必要である（図7・8・9）。



（図7）学習時に使用した画像での正解画像結果



（図8）初めて判断に用いた画像での正解画像結果



（図9）初めて判断に用いた画像での不正解画像結果

#### 2.2.4 山間部に存在する円墳を対象

Mask R-CNN と前方後円墳 GeoJSON を利用した手法では画像内に前方後円墳らしき形状が見られるかどうかを解析するアプローチを行なった。この手法では教師データ作成のための前方後円墳 GeoJSON を手動で作成する必要があり、教師データの拡充が困難であった。また、平地部にある前方後円墳については、既に整備されている古墳、もしくは開発済みの古墳が多数あり、これらを教師データに用いた場合、本来目的とする結果に影響する。そのため、山間部にある前方後円墳のみを対象にする必要があるが、その場合、教師データとしての必要な数を揃えることが困難となる。そのため、山間部にある円墳・方墳を主体とした分析にすることとした。



### 3. CS 立体図による機械学習

#### 3.1 兵庫県 50cm メッシュの CS 立体図

2022 年 10 月、兵庫県農林水産部治山課および国土交通省近畿地方整備局六甲砂防事務所から兵庫県の県土データとなる 50cm メッシュの提供をうけた（兵庫県は同データを 2023 年 1 月に公開（図 10））。2021 年度は DEM を機械学習処理したが、22 年度は CS 立体図の画像ベースにて機械学習を実施した。



(図 10) 兵庫県 50cm メッシュ

#### 3.2 処理フロー

##### 3.2.1 データ準備


データは、兵庫県 50cm メッシュ CS 立体図 (<https://www.geospatial.jp/ckan/dataset/2022-hyougo-geo-cs>)、山林範囲の特定のための国土数値情報：森林地域データ ([https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-A13-v3\\_2.html](https://nlftp.mlit.go.jp/ksj/gml/datalist/KsjTmplt-A13-v3_2.html))、既知の古墳データ把握のため、遺跡抄録・遺跡 DB の「兵庫県」の「古墳」データの 3 種を利用した。

##### 3.2.2 グリッドの作成・既知の古墳箇所を抽出


CS 立体図を全てダウンロードし、マージしたのち、EPSG：3857 に投影変換した。CS 立体図は兵庫県全域存在するわけではないことに留意が必要である。グリッドは将来的に CS 立体図以外のデータでの解析を視野に入れ、ラスタータイルのズームレベル 18 相当の位置・サイズで定義した。CS 立体図が存在し、兵庫県の領域かつ海を除いた地上部分のうち、森林区域ポリゴン内部のグリッドのみ抽出した。さらに、グリッドの領域の一部だけ CS 立体図が存在しないなどの不備のあるデータは除去した。グリッドの総数は 173107 グリッドとなった（1 グリッド 152.87 m）（図 11）。2021 年度までの解析とは異なり、古墳形状に注目するのではなく、既存の古墳が存在する「箇所」を抽出した。遺跡 DB は一部のデータ

がポリゴンであるため、重心点を抽出した。遺跡抄録・遺跡 DB の古墳ポイントに重なるグリッドを抽出した。結果、抽出されたグリッドは 817 グリッドとなった。

森林区域内のグリッドのうち、教師データの数量を均一にする目的で、古墳が存在する箇所と存在しない箇所を同じ個数抽出した。古墳が存在するグリッド 817 個  $\times$  2 = 1634 グリッドとなった。グリッドの範囲で CS 立体図から学習用の行列を抽出し、行列を水平・垂直フリップ、回転などを加え、教師データのバリエーションを増やした (図 12)。




(図 11) 分割されたグリッド群の一例



(図 12) 抽出したグリッドに沿って画像を抽出

### 3. 2. 3 モデルの作成・古墳存在予測スコアを算出

Python の機械学習フレームワークである「PyTorch」(<https://pytorch.org/>) を利用し、ResNet18 モデルを作成した。古墳有りグリッドと古墳無しグリッドを同じ数、学習させた。作成したモデルに森林区域のグリッドを予測させた。予測した箇所のグリッド (ポリゴン) に予測結果のスコアを付与した。予測結果は「古墳なし」・「古墳あり」の 2 ラベルに分類される。スコアは 0 ~ 1 に正規化し、高ければ高いほど該当するラベルである可能性が高いと判定される (図 13)。



(図 13) 予測スコアを可視化 (高いほど赤い)

例：以下の場合古墳が存在する可能性が高い。

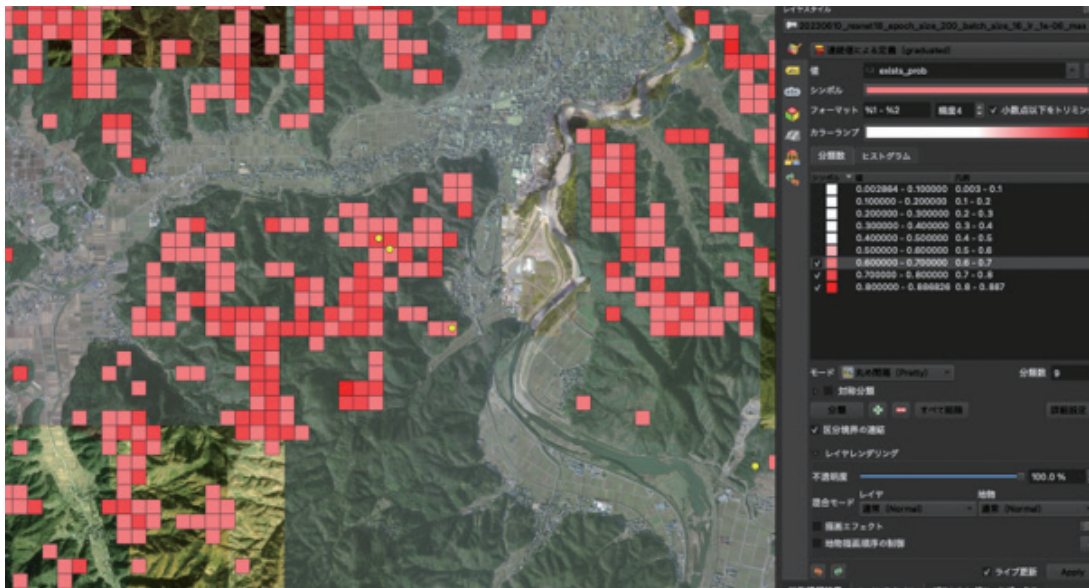
「古墳なし」：0.25

「古墳あり」：0.75

検証の結果は正解率 77% 程度となった。正解率は AI 自体のおおよその性能を示す。検証では、「古墳あり」と「古墳なし」のグリッドを 1 対 1 の比率になるようランダムに抽出し、学習済みモデルにグリッドを与えた。予測スコアが 0.5 を超えているときに「古墳あり」、それ以下の場合が「古墳なし」と判定するよう設定し、その結果、77% 正解することができた、という意味である。

#### 4. おわりに

予測スコアと新規発見古墳の位置情報を重ねて表示すると、発見された古墳は一部、高スコアグリッドと重なることがわかった(図14)。しかしながら、機械学習にて古墳が存在する可能性が高い場所を抽出しても、多数の候補地がある。そこで、ドメイン知識のGISデータ化や経験による絞り込みは必要となった。今後、地形データのさらなる高精度化、教師データとなる遺跡位置情報の増加、機械学習ライブラリの性能向上によって、よりの確に遺跡候補地を抽出できるようになるだろう。



(図14) 古墳存在予測スコア