

## 論文

## 移動体センシングによるディープラーニング技術の開発

Development of Deep Learning Technologies by Mobile Sensing

藤田 晴啓\*, 山本 亮\*, 河原 和好, 板垣 正敏, 市川 健太†, 南雲 彩花†

Fujita Haruhiro, Yamamoto Ryo, Kawahara Kazuyoshi, Itagaki Masatoshi,  
Ichikawa Kenta and Nagumo Ayaka

## 概要

車載カメラ画像のファインチューンド Mask R-CNN モデルによる道路表面物セマンティックセグメンテーション、および土器 3D-RGBA データの疑似ラベル教師あり分類・クラスタリングモデルによる導出クラスターと専門家分類のマッチング検証を行った。前者は4つの COCO データセット事前学習 Mask R-CNN モデルを12クラスの道路損傷等ラベル付 15,881 セグメンテーションデータでファインチューニングを施し、推論および検証を行った。Mask R-CNN Inception ResNet101 Atrous COCO が学習と推論で優れた結果を示した。東京国立博物館所蔵6世紀須恵器の光学スキャナー計測データを3D-RGBA Voxel ベースに変換し、Multi View ベースを併用して疑似ラベル教師あり分類・クラスタリングモデルによりクラスターを導出した。須恵器身の色情報なし3Dデータから導出されたクラスターID3には専門家分類型式のII-4、特にII-5が多く集中し、クラスターID5には専門家分類型式のII-1とII-2が集中する傾向が明らかとなった。その他のクラスターでは専門家分類型式が分散し、クラスターと専門家分類の大きな乖離がみられた。

**キーワード:**Mask R-CNN モデル セマンティックセグメンテーション 3D-RGBA Voxel ベース 疑似ラベル教師あり分類・クラスタリングモデル 土器型式分類の検証

## 1 研究の背景

深層学習が著しく発展したのは2010年代に入って次々と開発された物体検知技術による貢献が大きいとされており、深層学習に代表されるAI技術は今やデータ駆動型社会の根幹となる情報処理技術となっている(北川ら, 2021)<sup>1)</sup>。本稿はセマンティックセグメンテーションによる道路表面損傷検知に関する研究、そして3D光学スキャナーによる3D-RGBAデータを教師あり畳み込み分類学習を組み込んだクラスタリングモデルにより考古遺物の型式同定へと応用した研究成果をまとめたものである。いずれの研究もデータ取得は、前者は車載4Kカメラ、後者は手持ち光学スキャナーによる移動体センシングという共通点がある。本稿では、発表された論文を引用しながら二つの研究の概要を紹介する。

## 2 道路損傷検知モデルの開発と検証

ここではFujita et al. (2020b)<sup>2)</sup>にて発表された論文の内容を説明する。

セマンティックセグメンテーションとは、あらかじめ設定したクラスごとに画像のピクセル単

\*fujita@nuis.ac.jp \* 東京国立博物館 †株式会社BSNアイネット

位で対象となるエリアを学習させたモデルによる、クラスごとのピクセルレベルでの検知を行うタスクである。すなわち、画像の全ピクセルがそれぞれいずれのクラスに属するかを推定することである。セマンティックセグメンテーションに関しては岡野原(2022)<sup>3)</sup>により諸技術が説明されているので参照されたい。3)によるとセマンティックセグメンテーションはピクセルごとに「クラスごとに設定した色による」「塗り絵」を実行することに等しいとしている。しかしこの場合だと、同じクラスでも複数の個体が画像上連続した場合、例えば群衆のような画像の場合、一様に「ヒト」と判別される。そこで個々の「ヒト」を「個体ごとに独立して判別する」アルゴリズム、すなわち「インスタンスセグメンテーション」タスクが必要となる。本研究では4つのMask R-CNNモデルを使用し道路表面物探知タスクを評価した。4つのモデルは80クラスのタグをつけた150万インスタンスセグメンテーションから構成されるMS COCOデータセットにより事前学習されたセマンティックセグメンテーションモデルである。さらにそれらのモデルを12クラスの道路表面物タグをつけた15,188インスタンスセグメンテーションデータによりファインチューニングを施した。

図1に処理フローを示した。COCOデータセットを事前学習した4モデルに12クラスから構成される道路表面物のタグを付けた15,188アノテーションデータ(TFRecord Files Train/Val, tf\_label\_map.pbtxt)を加えてファインチューニングを行い、ファインチューンドモデルを得る(左から1~3列)。それに検証テスト用データを入れて推論結果による混同行列および各クラスにおける適合率および再現率による評価を行う(最右列)。

12クラスの道路表面物とは、1)線状亀裂、2)網目状亀裂、3)ジョイント、4)パッチ、5)充填、6)陥没穴、7)マンホール、8)シミ、9)影、10)区画線、11)区画線損傷、12)パッチ網目状亀裂である。学習に使用した15,188インスタンスのアノテーションのうち、最多は11)区画線損傷の3,503であり、その次は1)線状亀裂の3,238であった。最もすくなかったものは12)パッチ網目状亀裂の109であった。以上のアノテーション作成は事前に道路会社から車載カメラによる道路撮影画像の12クラス道路表面物の分類指導を受けたオペレーターが手作業で実施した。

この研究でテストされたCOCOデータセット事前学習Mask R-CNNモデルは以下の4モデルである。

Mask RCNN Inceptions v2 COCO

Mask RCNN Inception ResNet v2 Atrous COCO

Mask RCNN Inception ResNet50 Atrous COCO

Mask RCNN Inception ResNet101 Atrous COCO

これらの4つのモデルを10万epochまで学習する過程のmean Average Precision(mAP)\*、Average Recall(AR)\*\*、Loss metrics\*\*\*推移を図2、図3および図4に示す。

4つの事前学習Mask R-CNNモデルで得られた結果を比較するとMask R-CNN resnet101 Atrous COCOが最高のmAPと、Average Precisions (small)、Average Recalls@100、Average Recalls@10およびAverage Recalls@100 (small)において優れた結果を示した。概して、mAPは学習epochが増すに従って緩やかに増加するが再現率ははすぐにピークに達した。

Mask R-CNN ResNet101 Atrous COCOモデルの推論適合結果を表す混同行列(図5)によると、多

\*各クラスの平均適合率を平均した値 \*\*平均再現率 \*\*\*損失関数

くの数の検出漏れ、すなわちモデルが検出された対象を現実の物体に適合できなかったことを示している。これは各混同行列の最後の水平行に見られる、多数の「分類されていない検出」クラスにて示されている。

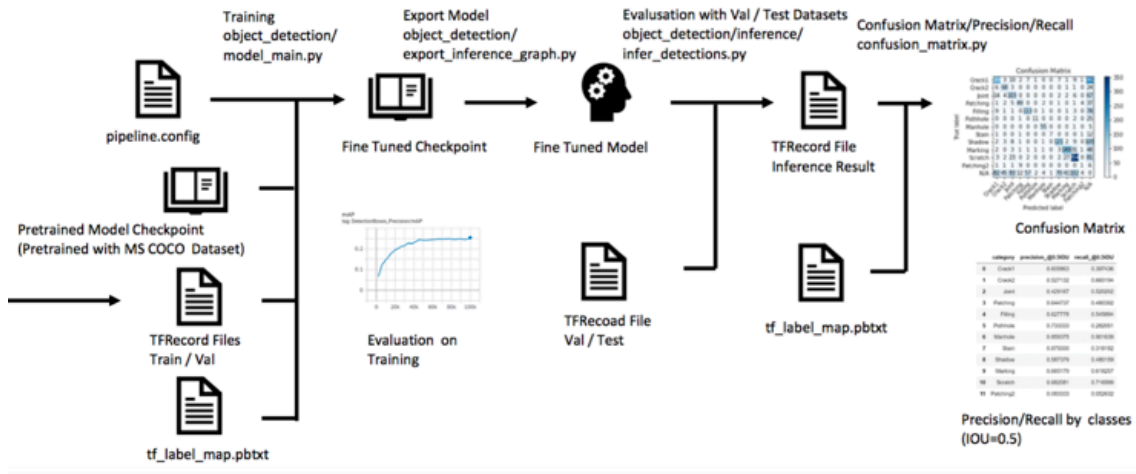


図1 Mask R-CNN model のファインチューニングと検証フロー(after Fujita et al. 2020b)

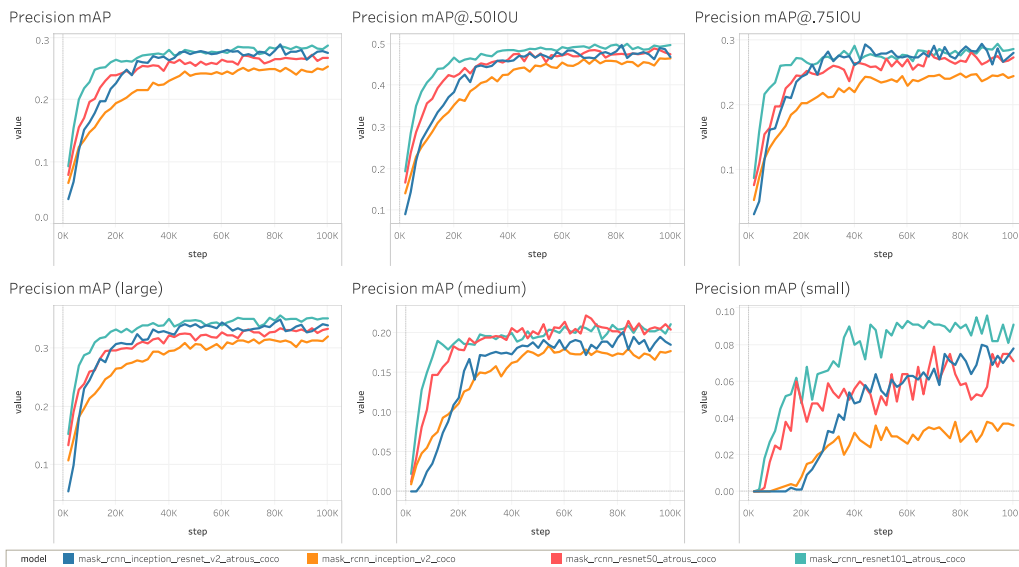


図2 学習過程における mAP(mean average precisions)の推移(after Fujita et al. 2020b)

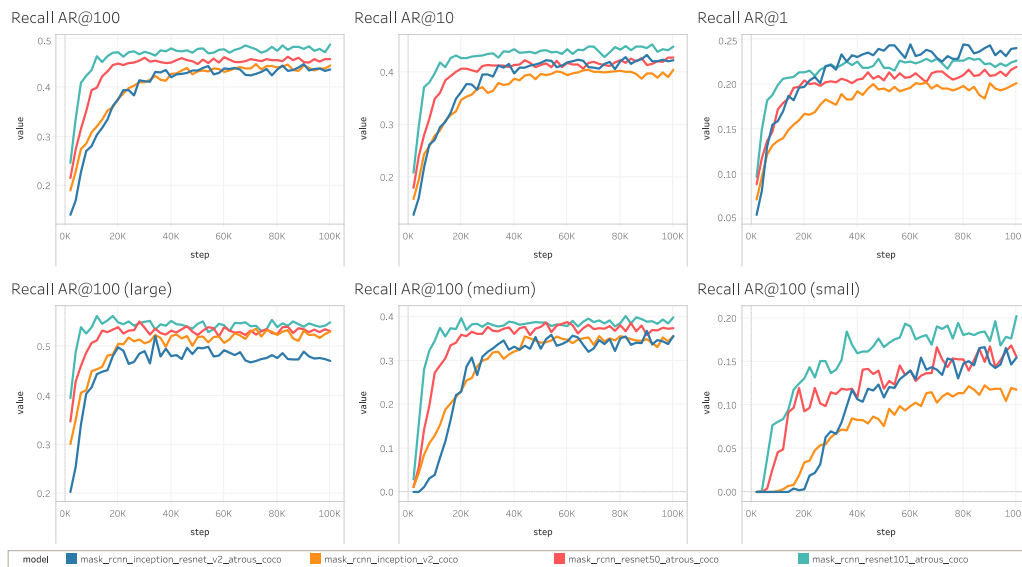


図3 学習過程における再現率の推移(after Fujita et al. 2020b)

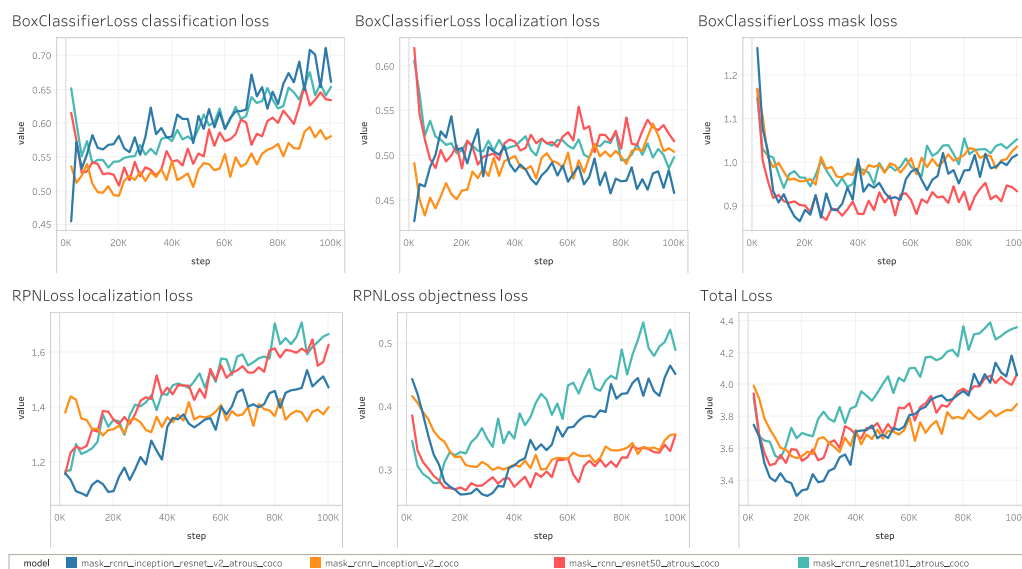


図4 RPN(Regional Proposal Network)の損失関数推移(after Fujita et al. 2020b)

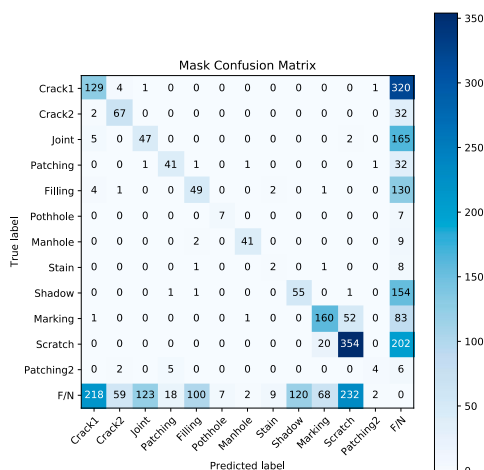


図5 Mask R-CNN Resnet101 Atrous COCO のMask 検出混同行列(after Fujita et al. 2020b)

表1に最も推論の結果が良好なMask R-CNN ResNet101 Atrous COCOの12クラスごとの適合率および再現率を示した。最も適合率が高かったクラスはマンホール0.91、パッチ0.63、次に網目状亀裂および陥没穴の0.5と続く。再現率ではマンホール0.79、網目状亀裂0.66、道路区画線損傷0.61と続く。表2にCOCOデータセットで事前学習した段階のモデルおよび道路表面物アノテーションデータでファインチューニングしたモデルのmAP (IOU=.50:.05:.95@100)を示した。この物体検知適合統計値によると道路表面物データでファインチューニングしたモデルの方がmAPは低いことは明らかである。しかしここでは推論する物体が全く異なる。COCOデータセットは150万の物体インスタンス(個別に認識される対象)画像に80種類のクラスタグが付いたもので、犬、自転車、ヒト、バス等物体認識上分類が明瞭な対象物ばかりである。一方、道路表面物データでは8種の道路損傷(補修跡も含む)およびその他4種の道路認識物(道路区画線、マンホール、シミ、影)といった全く一般的でない、しかもCOCOデータセット数と比較するとはるかに少ない識別対象物アノテーションデータで学習しており、結果が悪いとは一概に言えない。

図6には異なるIOU値によるGround Truth(正解エリア:赤枠)とEstimated Box(推定ボックス:緑枠)の重なり具合を模式的に示した。IOU値の計算は赤枠と緑枠が重なった面積を赤枠・緑枠の外縁で占められる面積で除したものである。この概念図から明らかなようにIOUが0.6に必要な重なりは0.6という数値で想像する重なり具合を超え、はるかに推定エリアが正解エリアに重なっている必要がある。逆に概念図一番右側は一見推定ボックスは完全ではないがおおよそ正解エリアに重なっているように見えるが、面積計算を行えばIOU値は0.3と低く算出される。

表2に示されたIOU=.50:.05:.95@100とはIOUが0.5以上の0.05間隔で積算した上位100のインスタンスIOU合計値を100で除した平均mean適合率のことであり、図6によるとIOU0.5とはかなりの正解と推定の重なりが必要なことからすると、算出されるmAPは想像するよりはるかに低い値となる。しかも推定されたセグメンテーションに自動的にレーザー照射を施しがん治療を行うような人命に関わるタスクではなく、IOUが0.3に達すれば道路補修という工事施工を現場に戻って行うため、よく推定できているとしたいところであるが、IOUが0.5以下は「不正解」と判断されるので、インフラ整備等で応用する深層機械学習のタスクとしては評価指数としては厳しすぎると考えられる。

最後にファインチューニング後の Mask R-CNN ResNet101 Atrous COCO の推論結果を図 7 に示した。各横方向の写真は、オリジナル、学習用アノテーション、推論結果（それぞれ左、中央、右画像）である。なおアノテーションおよび推論結果はピクセル単位でのマスクセグメンテーションとともにバウンディングボックス（対象ピクセルを囲む矩形枠線）で表示されている。上段の事例ではアノテーションで示された区画線および線状亀裂は推論では区画線はよく推論されているが、画像手前の線状亀裂を認識していない。中段画像のアノテーションでは画像全体の網目状亀裂をひとつのインスタンスとして指定していたが、推論結果では同じ網目状亀裂クラスでふたつの異なるインスタンスとして重なった状態で認識している。しかも画像中央下の網目状亀裂箇所が推論されていない。下段画像ではアノテーションで指定した区画線および区画線損傷は概ねよく推論されている。

Fujita et al. (2020c)<sup>4)</sup>では Mask R-CNN モデルによるバウンディングボックスとセグメンテーションマスク検知能力を比較・評価した。Fujita et al. (2020b)<sup>2)</sup>の道路表面物データでファインチューニングしたモデルではバウンディングボックスの方がセグメンテーションマスクより顕著に検知能力が高かった。線状亀裂、ジョイント、充填、影の適合率と再現率の調和平均値において顕著にその検知能力の差がみられたが、その他のクラスではほとんど差異はみられなかった。この論文ではバウンディングボックスおよびセグメンテーションマスク検知器の物体検知アルゴリズムについて議論している。詳細は論文を参照されたい。

表 1 Mask RCNN ResNet101 Atrous COCO の適合率・再現率  
(after Fujita et al. 2020b)

tag	precision_@0.5IOU	recall_@0.5IOU
Crack1	0.3593	0.2835
Crack2	0.5038	0.6634
Joint	0.2733	0.2146
Patching	0.6308	0.5325
Filling	0.3182	0.2620
Pothole	0.5000	0.5000
Manhole	0.9111	0.7885
Stain	0.1538	0.1667
Shadow	0.3143	0.2594
Marking	0.6400	0.5387
Scratch	0.5523	0.6146
Patching2	0.5000	0.2353

表 2 事前学習 4 モデルの微調整学習前後の mAP (IOU=.50:.05:.95@100) 比較  
(after Fujita et al. 2020b)

Model	Pre-trained model on COCO Dataset	Fine-tuned model with Road Dataset
mask_rcnn_inception_resnet_v2_atrous_coco	0.36	0.290
mask_rcnn_inception_v2_coco	0.25	0.254
mask_rcnn_resnet50_atrous_coco	0.29	0.268
mask_rcnn_resnet101_atrous_coco	0.33	0.288




図6 IOU(Intersection Over Units)の概念図 (赤枠 ground truth, 緑枠 estimated box)




図7 微調整学習後のMask RCNN ResNet101 Atrous COCOの推論結果

(after Fujita et al. 2020c)

### 3 須恵器 3D-RGBA データの深層クラスタリングモデルによる型式学的解析と検証

クラスター解析はデータサイエンス手法の一つで、これまでヒトがさまざまな情報から行ってきた主観的な要素が入る分類とは異なり、純粋に数理処理で未知のクラスターを検知する技術である。考古学の教師付分類タスクでは多数の出土資料画像データとそれぞれの型式あるいは年代ラベルという分類の正解（教師データ）を畳み込み学習ニューラルネットワーク (CNN) モデルに学習させ、未分類の画像データの型式や年代を推測する研究が多い。本研究では 3D データを使い、クラスタリングによる未知のグループの疑似ラベルをループでモデルの途中に戻し、教師あり CNN 学習とクラスタリングを繰り返すことにより、専門家がこれまで分類したことのない基準でクラスターを創出できる独創的な解析モデルによる「ヒトの判断基準の妥当性の検証」を目的とする。

市川ら (2021)<sup>5)</sup>は、画像データによる分類を実施する研究では、研究の対象物は一般的なモノでないことが多く、そのような対象物は学習用に多量のデータを揃えることは概して困難である。そこで ImageNet や、前述道路表面物解析で使用した COCO 等の大規模データセットで事前学習したモデルを、分類対象物の少数のデータセットで転移学習やファインチューニングを行って精度を確保する手法が一般的であるとしている。

転移学習とは事前学習したモデルの出力層のみを目的のタスクに書き換える手法であり、出力層以外のネットワーク層のパラメータは事前学習時に固定する方法である。ファインチューニングはモデルの出力層を目的のタスクに書き換えるが、ネットワーク全体のパラメータは固定せずに新たなファインチューニング用の学習データで微調整を行う。

3D 解析では未だ ImageNet や COCO のような大規模のデータセットは存在せず、本研究では ModelNet10(10 クラスの 4899 インスタンス 3D 家具データ) 事前学習モデルを利用した。

また、深層学習における 3D 物体認識タスクに使用されるデータベース型式は、RGBD ベース、点群データ利用、Voxel ベース、そして Multi View ベースが一般的である<sup>5)</sup>。

図 8 にデータ取得に用いた Creaform 社製光学スキャナー GoScanSpark を示した。このスキャナーはプロジェクター（上から 2 番目）により 99 本の平行白色線を物体に照射し、トラッキングカメラ（上から 1、3、5 番目）により同じ平行白色線の形状の差から物体の 3D 形状をデータ化する。カラーカメラ（上から 4 番目）は物体の RGB テクスチャーデータを取得すると同時に物体をトラッキングする際、形状に加え色情報も同時に使われる。

図 9 は光学スキャナーによるデータ作成を模式的に示した。XYZRGB 点群情報はスキャナー読み取りソフトによりメッシュデータに変換される。それを Object 形式のファイルとして出力し、新たに本研究にて開発した Voxel 化プログラムにより任意の解像度の RGBA-Voxel ベースに変換する。Voxel ベースとは 2D の Pixel データに Z 方向の奥行きが加わった立方体の単位で構成されるデータベースで、図 9 では異なる解像度による須恵器身の Voxel データを図化した。解像度の違いによる差異は非常に大きいことが判別できる。RGBA チャンネルのうち A は Alpha(アルファ)チャンネルのことで個々の Voxel の透明度を表す。



図 8 光学スキャナー GoScanSpark



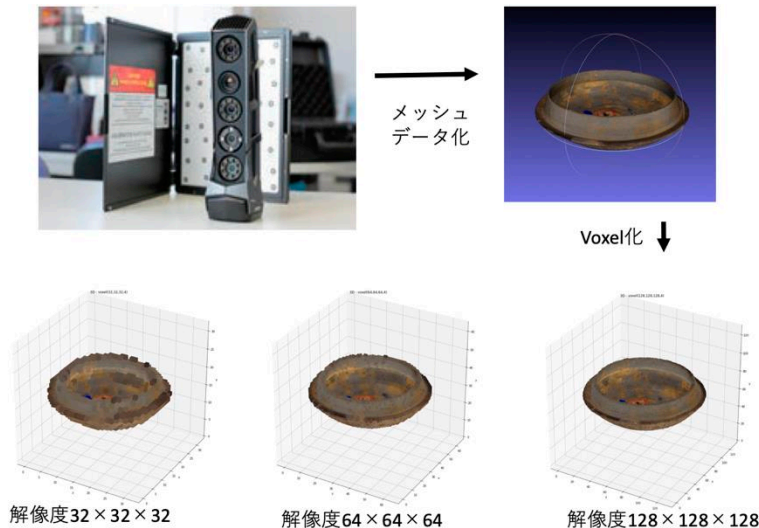


図9 メッシュデータ化および3つの解像度におけるVoxel化

さらに本研究では、作成されたVoxelデータをY軸を中心に $30^\circ$ ずつ回転させるMulti View手法によりひとつのVoxelデータから12のデータを作成している。したがって、本研究は市川ら(2021)<sup>5)</sup>が定義したVoxelベースとMultiViewベースを組み合わせたデータベース手法となる。

論文6)では事前学習したModelNet10を用い「疑似ラベル教師あり分類・クラスタリングモデル」という従来の教師あり学習にクラスタリングを組み込んだモデルを使用した。須恵器の解析ではエルボー法により10クラスターと $64^3$ Voxel解像度により分類クラスと導出クラスター間に有意な関連性はみられなかった。

論文7)8)では解析手法の改善により若干の分類クラスといくつかのクラスター間の関連性が見られたが依然解像度が低く、新たに導入したGrad-CAM値によるヒートマップ可視化では、須恵器がないVoxel透明部分が参照されてクラスタリングされた可能性が高いことが示唆された。

東アジア考古学会国際会議9)および仏日考古研究会発表10)では形状のみの $128^3$ Voxelベースを用い、クラスター数を6に設定した解析によると、クラスターID3およびID5が有意な結果が得られたので、以下に概略を説明する。

須恵器編年を大系化した中村浩氏による分類(型式および年代)が報告されている東京国立博物館所蔵6世紀の完形・略完形須恵器坏、蓋49点(表2)、身59点(表3)の計108点を0.5mmのスキャン精度で計測される3D-RGB点群情報(図10①)は形状・色処理ソフトにてポリゴン・テクスチャデータとして保存され、さらにobjファイル群として出力する。objファイル群を3D-RGBAの情報を持つVoxelベースに変換するプログラムを開発し変換を行い $128 \times 128 \times 128$ の解像度にて出力した(②)。須恵器資料ごとのVoxelベースは平面上に須恵器を置いた場合の垂直方向を軸として $30^\circ$ ずつ回転し、データ拡張を行った。③疑似ラベル(初回はランダムラベル)を教師とする3D畳込みモデルで学習を行い、④得られた特徴ベクトルにより⑤k-平均法主成分分析・クラスタリングを行った。⑥クラスタ結果は疑似ラベルとして③の教師付き学習に戻され、③～⑥を50epoch繰り返した後、⑦主成分分析・t分布確率的近傍埋込による可視化を行った。

表 2 須恵器蓋データ

年代 (6世紀)	型式	
前葉	II-1	6
	II-2	6
中葉	II-3	14
後葉	II-4	8
	II-5	15
総計		49

表 3 須恵器身データ

年代 (6世紀)	型式	
前葉	II-1	7
	II-2	7
中葉	II-3	16
後葉	II-4	13
	II-5	16
総計		59

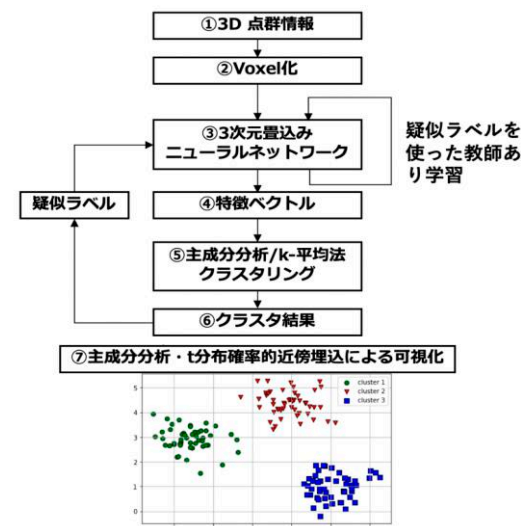


図 10 疑似ラベル教師付分類+クラスタリングモデル

色情報 RGB を含まない形状だけの 3D-A データ解析では、まずデータ拡張によるクラスの分散が発生していないことを主成分分析で確認を実施した。すなわちデータ拡張により作成された同じクラスのデータは全て同一クラスターに含まれることを確認した (図 11)。さらに正規化されたデータをエルボー法により最適なクラスター数は 6 と決定した (図 12)。

須恵器編年を大系化した中村浩氏の型式・年代分類と 6 クラスターの混同行列 (図 13) を作成した。クラスター分散は専門家のふたつの型式分類で固まる傾向にあった。図 13 横方向は専門家による型式分類、縦方向はクラスター群を表す。クラスター ID3 には専門家分類型式 II-4、特に II-5 が多く集中し、同様にクラスター ID5 には専門家分類型式 II-1 と II-2 が集中する傾向が明らかとなった。一方その他のクラスターでは専門家分類型式が分散し、クラスターと専門家分類の大きな乖離がみられた。

報告 11) 12) では論文 6) 7) 8) 9) 10) にて報告したクラスター解析ではなく、3DCNN (三次元畳み込みニューラルネットワーク) を補完する目的で、三方向 (真上, 真横, 真下) の画像を解析する 2DCNN ネットワークを加えた。すなわち 3DCNN を含むモデルに加え 3 つの独立した 2DCNN 合計 4 モデルが並列に並ぶ構造のモデルを構築して解析を進め、ある程度の分類能力が認められた。

13) 14) 15) では本報告と同じ手法を用い縄文土器のクラスター解析結果を報告しているが、サンプル数が少なく、個体差の大きさ等の理由で未だ有意な結果は得られていない。

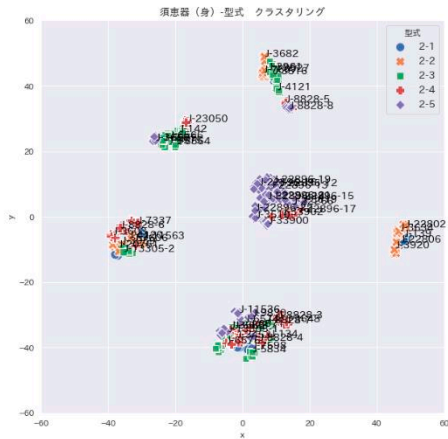


図 11 須恵器身拡張データのクラスター結果




図 12 エルボー法によるクラスター数決定

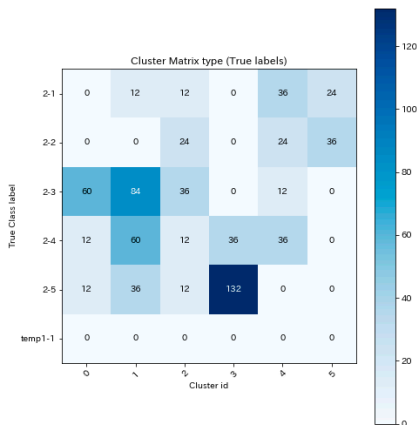


図 13 専門家判別クラスとクラスター混同行列

## 謝辞

本稿は令和2年度から令和4年度まで新潟国際情報大学の「共同研究型プロジェクト研究」に採択され研究助成を受けた「ディープラーニングによる移動体センシング技術の開発」を総括する報告書である。研究助成のおかげで広い分野で多くの成果を公表することができ同学への感謝とともに研究にご協力いただいた大学関係者、さらには一連の研究にご協力いただいた科学研究費補助での研究代表者河野一隆さま（九州国立博物館学芸部長）および研究協力者として市川健太さまおよび南雲彩花さま（株式会社BSNアイネット）、そして板垣正敏さまにこの場を借りて謝意を表したい。道路表面物識別モデル開発では画像データ提供および損傷クラスと箇所のご指導をいただいた福田道路株式会社さまに謝意を表したい。

学外からは以下の研究助成を受けた。ここに謝意を表する。

基盤研究(B) (一般) 22H00744 (R4-R6) 研究代表 藤田 晴啓

須恵器 3D-RGB データの深層学習クラスター解析による型式・年代分類基準の検証

基盤研究(B) (一般) 22H00748 (R4-R7) 研究代表 河野 一隆

統計的画像処理と機械学習を併用した文化財のデジタル復元技術の基盤創出

挑戦的研究(萌芽) 22K18496 (R4-R6) 研究代表 河野 一隆

文化財デジタル復元のための統計的画像処理および機械学習技術の創出  
また報告 9)11)および 12)では以下の科研費の支援を受けたので謝意を表したい。

学術変革領域(A) (公募) 21H05359 (R3-R4)

3D マルチ入力・マルチ出力土器分類 DL モデルの開発研究 研究代表 山本 亮

## 参考文献

- 1) 北川源四郎・竹村彰通編 2021, 教養としてのデータサイエンス 講談社
- 2) Fujita et al. 2020b. Fine-tuned Pre-trained Mask R-CNN Models for Surface Object Detection. <https://arxiv.org/abs/2010.11464>
- 3) 岡野原大輔, ディープラーニングを支える技術 「正解」を導くメカニズム[技術基礎], 技術評論社 2022, p240-246.
- 4) Fujita et al. 2020c. Detector Algorithms of Bounding Box and Segmentation Mask of a Mask R-CNN Model. <https://arxiv.org/abs/2010.13783>
- 5) 市川健太, 板垣正敏, 山本亮, 藤田晴啓  
須恵器 3次元計測データによる分類解析モデルの検討, 考古文化財ディープラーニング研究会発表論文集, 2021 <http://id.nii.ac.jp/1608/00003391/>
- 6) 藤田晴啓, 山本亮, 板垣正敏, 市川健太, 宮尾亨, 河原和好  
土器 3D-RGB データの深層学習クラスター解析による型式・年代分類基準の検証, 考古文化財ディープラーニング研究会発表論文集, 2021 <http://id.nii.ac.jp/1608/00003396/>
- 7) 藤田晴啓, 山本亮, 河原和好, 市川健太, 南雲彩花  
須恵器 3D-RGB データの擬似ラベル教師分類+クラスターモデル開発と Grad-CAM によるモデル判別の可視化, 日本情報考古学会第 46 回大会講演論文集 (2022)
- 8) 藤田晴啓  
須恵器 3D-RGB データの深層学習クラスター解析による型式・年代分類基準の検証, 第 2 回考古文化財ディープラーニング研究会発表要旨集, 2022 <http://id.nii.ac.jp/1608/00003503/>
- 9) Fujita Haruhiro, Yamamoto Ryo, Ichikawa Kenta, Nagumo Ayaka  
Verification of pottery type and dating criteria by deep learning cluster analysis of 3D-RGB data, 9th Conference of Society of East Asia Archaeology, Session 9, A new perspective for pottery study in Japan, 29 June 2022
- 10) 藤田 晴啓, 山本 亮, 市川 健太, 南雲 彩花  
須恵器 3D-RGBA 深層学習による導出クラスターおよび考古学型式分類の乖離およびマッチング, 仏日考古研究会発表資料, August 2022 <http://id.nii.ac.jp/1608/00003519/>
- 11) 山本亮, 藤田晴啓, 河原和好, 市川健太, 南雲彩花  
須恵器マルチヘッド・マルチタスク 3D-2D-CNN モデルの開発  
日本情報考古学会第 46 回大会講演論文集 (2022)
- 12) 藤田晴啓, 市川健太, 板垣正敏, 山本亮  
マルチヘッド・マルチタスク 3D-2D-CNN モデルの開発  
考古文化財ディープラーニング研究会発表論文集, 2021 <http://id.nii.ac.jp/1608/00003393/>
- 13) 宮尾亨, 藤田晴啓, 板垣正敏, 市川健太, 南雲彩花, 河野一隆

縄文土器 3D-RGB データの深層学習クラスター解析に向けた Voxel 化および解像度の評価  
日本情報考古学会第 46 回大会講演論文集 (2022)

14) 板垣正敏, 市川健太, 藤田晴啓, 宮尾亨

縄文土器 3D 計測データによるクラスター解析モデルの検討

考古文化財ディープラーニング研究会発表論文集, 2021 <http://id.nii.ac.jp/1608/00003392/>

15) 宮尾亨, 藤田晴啓, 板垣正敏, 市川健太, 南雲彩花, 河野一隆

3D 深層学習クラスター解析を目的とした光学スキャナーによる縄文土器計測, 第 2 回考古文化財  
ディープラーニング研究会発表要旨集, 2022 <http://id.nii.ac.jp/1608/00003509/>