

# 動物医用画像を用いた立体画像解析に関する研究

Research on stereoscopic image analysis using animal medical images

鈴木 百音  
指導教員 佐藤 公則

1) 東京工科大学大学院 バイオ・情報メディア研究科 コンピュータサイエンス専攻

本研究では、動物医用画像における病変部の早期発見を目指し、3D U-Net を用いた立体画像解析を行った。Kaggle のデータセットを活用し、精度向上のためのデータ拡張や正規化を実施。結果として、従来の2D 解析と比較して精度向上が示唆され、動物医療への応用可能性を確認した。

キーワード (必須) : 医用画像, 病変部検出, 立体画像解析, 3D U-Net

## 1. はじめに

現在、国内の医師の総数は増加傾向にある一方で、地域や診療科によって医師が偏っており、都市部等の一部エリアに医師が集中し、地方は医師不足に陥っている。撮影技術と医療機器の進歩により医療画像が増え続けているが、診療する放射線科医が不足しているため、医用画像から病変候補を漏れなく検出して、医師に提示する機能が医療現場で期待されている。この技術は、人間医療だけでなく、動物医療の分野においても応用できると考えており、画像解析技術の精度向上により人も動物も安心して暮らすことができる社会を実現することに貢献できると考えている。

## 2. 目的と意義

本研究における目的は、動物医用画像において病変部検出を行うことである。人間の場合、患者は自身の症状や感覚を言語で伝えることができるが、動物は自分の症状や不快を直接伝えることができないため、動物の行動や外傷から適切な診断と治療をする必要がある。画像解析をすることで疾患の早期発見をすることで、ひとつでも多くの動物の命を救うことができると考えられる。また、立体画像解析を実現することができれば、人間医学の分野でも応用できると考えられる。

## 3. 新規性

本研究は動物医用画像を用いて立体画像解析をすることが新規性であると考えられる。しかし、立体画像解析には多くの課題があり、研究途上の分野であると言える。最も大きな課題として、データ量が膨大であることが言える。MRI 画像は本質的には幅×高さ×深さの3D の情報を有しており、2D のUNet ではこれを幅×高さの2D の画像として学習するため、深さ方向の情報を失っていると考えられる。そこで、3D で UNet を実装し、2D と同様に臓器の領域を予測することが可能か調べる。

## 4. 方法

### 4.1 データセット

Kaggle の「UW-Madison GI Tract Image Segmentation」のデータセットを使用した。本コンペティションは MRI の画像から小腸大腸胃の領域を予測し、その精度を競うものである。

### 4.2 使用する技術

#### 4.2.1 3D U-Net

3次元の畳み込み層を用いて MRI 画像のセグメンテーションを行う。

#### 4.2.2 データ拡張

モデルの汎化性能を向上させるために、回転、スケーリング、シフト、フリップなどのデータ拡張を行った。

#### 4.2.3 正規化

MRI 画像特有のノイズやアーチファクトを除去するために、ピクセル値の正規化を行った。

## 5. UNet の概要

UNet は、生物医学画像のセマンティックセグメンテーションのために開発されたモデルである。エンコーダは画像の特徴を抽出し、デコーダはその特徴を用いて元の画像と同じサイズのセグメンテーションマップを生成する。エンコーダとデコーダの間には skip connection があり、これにより位置情報を保持しつつ高精度な予測が可能である。

## 6. 手順

### 6.1 データ準備

Kaggle から「UW-Madison GI Tract Image Segmentation」データセットをダウンロードし、トレーニング、検証、テスト用に分割する。データは、80%をトレーニングデータ、10%を検証データ、10%をテストデータとして分割する。データ拡張技術を用いて、トレーニングデータのバリエーションを増やし、モデルの汎化性能を向上させる。具体的には、回転、スケーリング、シフト、フリップ、ノイズ付加を行う。

### 6.2 モデルの構築

3DU-Net の構造を実装する。エンコーダとし 畳み込み層とプーリング層を用いて、画像の特徴を段階的に抽出する。つぎにデコーダとして畳み込み層とアップサンプリング層を用いて、特徴マップからセグメンテーションマップを生成する。最後に Skip Connection としてエンコーダの各層の出力を対応するデコーダの入力と結合し、位置情報を保持する。

### 6.3 モデルのトレーニング

トレーニングデータを用いて、モデルを訓練する。損失関数として、クロスエントロピー損失やダイス損失を使用する。

## 7. 研究結果

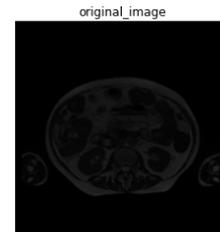


図1 元画像

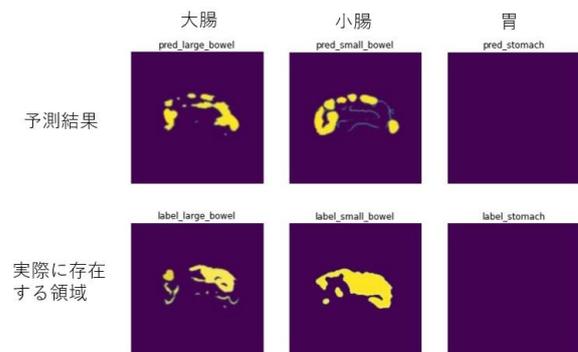


図2 予測結果

予測結果をもとに 2D UNet との精度評価をしたところ、平面画像は物体の形状しか捉えることができず、3次元情報を保持した画像を用いた解析の方が精度向上に有効だと考えられる。また、精度向上のためにデータの拡張と正規化を行った結果、改善前よりも精度が向上していた。

## 8. おわりに

予測結果をもとに 2D UNet との精度評価をしたところ、平面画像は物体の形状しか捉えることができず、3次元情報を保持した画像を用いた解析の方が精度向上に有効だと考えられる。畳み込み第1層の出力チャンネル数を減らしたことが原因の可能性であると考えられる。また、精度向上のためにデータの拡張と正規化を行った結果、改善前よりも精度が向上していた。

## 9. 参考文献

UNet とは

<https://www.skillupai.com/blog/tech/segmentation2/>

UW-Madison GI Tract Image Segmentation

<https://www.kaggle.com/competitions/uw-madison-gi-tract-image-segmentation/overview>