

# 3次元心臓モデルのための動作補間手法の構築

チャン チュジェ<sup>1,a)</sup> 宮内 翔子<sup>2</sup> 諸岡 健一<sup>3</sup> 倉爪 亮<sup>2</sup>

**概要:** 医用画像の一つである心臓 MRI (Magnetic resonance imaging) は、心疾患の診断のために広く用いられている。しかし、心臓 MRI の撮像時間は約 50 分と長く、撮像コストや患者への負担が大きい。撮像時間を短くした場合、得られる画像のフレームレートが低下し、そこから観察される心臓の動きの時間分解能も低下する。心疾患の診断では、心臓の動きの観察が重要となるため、時間分解能の低下により、診断精度が低下する恐れがある。そこで、我々は、短時間で撮像された時間分解能の低い心臓 MRI から、高い時間分解能の心臓の動きを推定するための生成ネットワークを提案する。提案ネットワークを用いることで、従来の生成モデルを用いた場合よりも高い精度で、心臓の動きの時間分解能を向上できることを確認した。

## 1. はじめに

心臓 MRI は、形態情報と機能情報の双方が得られる非侵襲的な検査法である。しかし、心臓 MRI の撮像時間は約 40 分と長く、その間患者は、機械音が鳴り響く狭い装置内で静止する必要がある。撮像時間を短縮した場合、撮像時の患者の負担や撮像コストを低減できる。一方で、撮像された MR 画像の時間分解能や空間解像度は低下し、医師による診断の精度低下につながる。

短時間で撮像された MR 画像の時間分解能や空間解像度を向上させる手法として、ニューラルネットワークを用いた手法が複数提案されている [1]。しかし、これらの手法では、空間解像度の向上や欠落した 1 フレームの補完のみを対象としており、時間分解能の向上を対象としている手法は少ない。

心疾患の診断では心臓の動きの観察が重要であり、心臓の形状変化をより高い時間分解能で観察できるようにすることで、心疾患の診断精度を向上できる可能性がある。そこで、我々は、低フレームレートの MR 画像から、高フレームレートの心臓の動きを推定する手法、Hybrid network を提案する。

## 2. Hybrid network

提案する Hybrid network は、心臓の動きから健常者と心疾患患者を分類するための生成モデル Ladder Variational Autoencoder (LVAE) + Multiplayer Perceptron (MLP)[2]

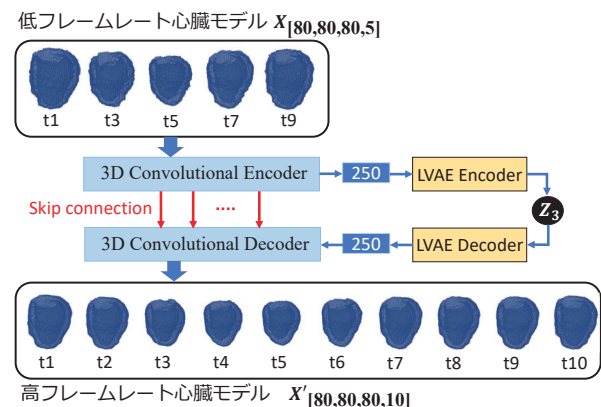


図 1 Hybrid network の概要

に、U-Net[3] のフレームワークを導入することで構築する (図 1)。Hybrid network では、入力された一心周期分の低フレームレートの心臓モデルから、高フレームレートの心臓モデルの推定を行う。ここで、一心周期とは、心臓が弛緩した状態から収縮し、再度弛緩するまでの期間を指す。

心臓モデルの生成では、まず、一心周期分の心臓の動きに対応する 10 フレーム分の MR 画像に Joint Learning model [4] を適用する。これにより、各フレームにおける左心室の心筋領域を自動抽出する。次に、抽出された左心室領域の 3 次元形状を表す  $80 \times 80 \times 80$  のボクセルモデル (図 2) を 10 フレーム分生成し、この 10 個のボクセルモデルの集合を、高フレームレート心臓モデルとする。さらに、奇数番目のフレームに対応する 5 個のボクセルモデルの集合を、低フレームレート心臓モデルとする。

Hybrid network は、LVAE+MLP を構成する 3D 畳み込みエンコーダ・デコーダ、LVAE、MLP から、分類のために用いられている MLP を除いたものがベースとなっている。

<sup>1</sup> 九州大学大学院システム情報科学府

<sup>2</sup> 九州大学大学院システム情報科学研究科

<sup>3</sup> 岡山大学大学院自然科学研究科

a) chang.chujie.381@s.kyushu-u.ac.jp

このベースに含まれる 3D 畳み込みエンコーダ・デコーダの各層に対して、U-net で使用されている Skip connection を導入する。これにより、高フレームレート化した際の各ボクセルモデルの生成精度の向上を図る。

図 1 に示すように、Hybrid network では、 $80 \times 80 \times 80 \times 5$  の低フレームレート心臓モデルが入力されると、5 層の 3D 畳み込みエンコーダで 250 次元の特徴ベクトルに圧縮する。この特徴ベクトルを 3 層の潜在空間からなる LVAE に入力し、16 次元の潜在変数  $z_3$  を得る。この  $z_3$  を 8 層の 3 次元畳み込みデコーダに入力することで、 $80 \times 80 \times 80 \times 10$  の高フレームレート心臓モデルを生成する。また、損失関数  $L$  は以下のように定義する：

$$L = k_i \sum_{i=1}^3 KL_i + \sum_{j=1}^{10} DSC_j \quad (1)$$

ここで、 $DSC_j$  は入力された時刻  $j$  のボクセルモデルと、それに対応する LVAE デコーダで生成されたボクセルモデルとの一致度を評価する Dice 係数である。 $k_i$  は  $i$  層目の潜在変数  $z_i$  の分布をガウス分布に近づけるための Kullback-Leibler 情報量であり、 $k_i$  は各項に対するスケール係数である。事前実験を通して、 $k_1 = 0.001$ ,  $k_2 = 0.001$ ,  $k_3 = 0.01$  とした。また、LVAE の各層の潜在変数  $z_1$ ,  $z_2$ ,  $z_3$  は、64, 48, 32 次元とした。

### 3. 実験と考察

データセットとして、UKBiobank [5] で公開されている健常者 210 名分の MR 画像を使用した。このデータセットを学習データ 180 名分とテストデータ 30 名分に分割し、分割方法を変えて 7 つのデータセット作成した。各データセットを用いて 5 回ずつ実験を行い、7 分割交差検証を行った。バッチサイズは 10、エポック数は 350 とし、最適化時には Adam Optimizer を使用した。学習率は  $e^{-3}$  とし、100 エポックごとに 0.5 倍した。Hybrid network を用いた場合と、これを構成する LVAE と U-net を個別に用いた場合の生成精度を比較するため、Hybrid network を用いた場合、LVAE のみを用いた場合、U-net のみを用いた場合の 3 パターンについて、それぞれ 7 分割交差検証を行った。

各パターンにおける奇数・偶数番目のフレームの平均 Dice 係数を表 1 の 2-3 行目に、全部フレームにおける平均 Dice 係数を 4 行目に示す。また、生成された高フレームレートの心臓モデルのうち、フレーム 1-2, 5-6 に対応するボクセルモデルの断面を図 2 に示す。図 2 の 1 列目に各フレームの真値を、2, 4, 6 列目に各パターンでの生成結果を、3, 5, 7 列目に真値と生成結果の差分画像をそれぞれ示す。

図 3 より、LVAE よりも U-net や Hybrid network の方が、生成されたボクセルモデルの形状が真値に近いことが分かる。また、表 1 より、全フレームにおいて、Hybrid network を用いた場合に Dice 係数が最も高いことが確認

表 1 テストデータに対する平均 Dice 係数

Method	Hybrid	LVAE	U-Net
奇数番目の平均	<b>0.94</b>	0.76	0.92
偶数番目の平均	<b>0.88</b>	0.71	0.87
AVG	<b>0.91</b>	0.73	0.90

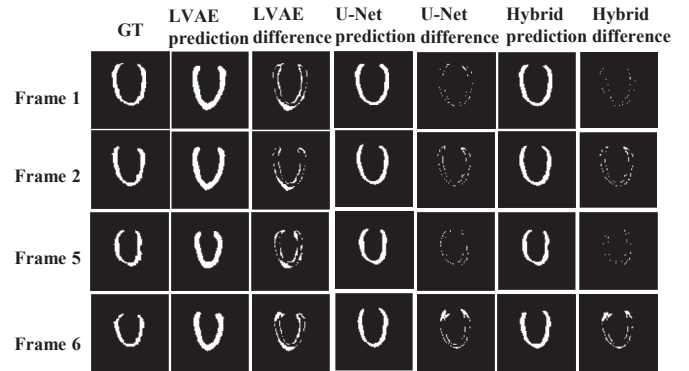


図 2 生成された心臓モデルの断面と真値との差分画像

できる。以上の結果より、LVAE や U-net を個別に用いる場合よりも、これらを組み合わせた Hybrid network の方が、高い精度で高フレームレートの心臓モデルを生成できるといえる。

また、表 1 に示すように、奇数番目よりも、偶数番目の Dice 係数が全体的に小さく、生成精度が低い。これは、奇数番目のフレームの情報は低フレームレートの心臓モデルとして入力されるのに対し、偶数番目のフレームの情報は、奇数番目のフレーム情報のみから推定されるためである。時刻による形状変化を考慮した特徴抽出が行えるよう、ネットワークを改良することで、偶数番目の生成精度向上を今後は目指す。

### 4. むすび

低フレームレートの心臓モデルから高フレームレートの心臓モデルを生成する Hybrid network を構築し、従来手法よりも高精度に心臓モデルを生成できることを確認した。

謝辞 本研究は JSPS 科研費 20K19924 の助成を受けた。

### 参考文献

- [1] Lyu, Qing, et al. "Cine cardiac MRI motion artifact reduction using a recurrent neural network." IEEE Transactions on Medical Imaging 40.8 (2021): 2170-2181.
- [2] Biffi, Carlo, et al. "Explainable anatomical shape analysis through deep hierarchical generative models." IEEE transactions on Medical Imaging 39.6 (2020): 2088-2099.
- [3] Ronneberger, Olaf, et al. "U-net: Convolutional networks for biomedical image segmentation." In International Conference on MICCAI, pp. 234-241, 2015.
- [4] Qin, Chen, et al. "Joint learning of motion estimation and segmentation for cardiac MR image sequences." In International Conference on MICCAI, pp. 472-480, 2018.
- [5] UKBiobank, <https://www.ukbiobank.ac.uk/> (2022/6/2)

## 正誤表

下記の箇所に誤りがございました。お詫びして訂正いたします。

訂正箇所	誤	正
講演題目	3次元心臓モデルための 動作補間手法の構築	3次元心臓モデルのための フレーム補間手法の構築