

LSTM を用いた AC-WGAN-gp でのデータ拡張による クラス不均衡不整脈心電図データ識別

Class Imbalance Arrhythmia ECG Data Discrimination by Data Expansion in AC-WGAN-gp Using LSTM

弓削 笑里[†] 杉本 千佳[‡]
Emiri Yuge Chika Sugimoto

1. はじめに

近年医療分野ではAI技術を導入し、画像や生体信号から病気を診断するニーズが高まっている。しかし、医療では一般的に正常データが多数で異常データは少なく、機械学習において不均衡データ問題が課題となる。この問題に対してはアンダーサンプリングやオーバーサンプリングといった方法があり、本研究では少数クラスを増強するために敵対的生成ネットワーク(GAN)を用いる。

GANを画像のデータ拡張に用いる例は多いが、クラス識別が難しい微細な変動を有する時系列データに適用した研究例は少ない。ECGのような生体データを入力とするクラス不均衡データの分類問題において、データ拡張により分類性能を向上させるため、時系列データに適した生成ネットワークモデルを提案する。

2. 提案手法

GANは生成器と判別器から構成される。不均衡データでのデータ生成においてモード崩壊を抑制するため、本研究では生成器と判別器を同時に学習する Wasserstein GAN (WGAN)[1]の改良型である WGAN-gp を用いる。WGANでは損失関数に Wasserstein 距離 (EMD) を用いて EMD を最小化することで学習するが、式(2.1)の最大化問題を解くことで近似できる。

$$W(P_r, P_\theta) = \max_{\omega \in \mathcal{W}} E_{x \sim P_r} [f_\omega(x)] - E_{z \sim p(z)} [f_\omega(g_\theta(z))] \quad (2.1)$$

ここで、 P_θ は生成器の出力分布、 P_r はデータ分布、 f_ω はパラメータ ω のリプシッツ関数で判別器、 g_θ はパラメータ θ の生成器を表す。

提案モデルの全体構成を図1に示す。生成器は時系列データに適した LSTM モデルとし、条件付き GAN である

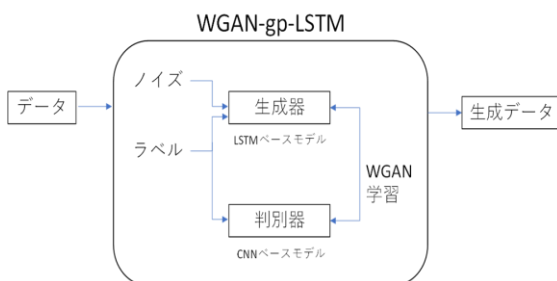


図 1 提案モデルの全体構成

[†] 横浜国立大学大学院理工学部 Graduate School of Engineering Science, Yokohama National University

[‡] 横浜国立大学大学院工学研究院 Faculty of Engineering, Yokohama National University

CGANを組み合わせた AC-WGAN-gp と WGAN-gp の 2 種類でデータを生成した。

分類器には、図 2 に示す深層畳み込みニューラルネットワーク (DeepCNN) に心電図データの分類性能が高い BiLSTM-Attention[2]を追加したモデルを用いる。




図 2 DeepCNN の構造

3. 評価実験

3.1 使用データ

本実験では、ECG の公開データから成る不整脈データベース MIT-BIH を使用する。MIT-BIH のデータは Association for the Advancement of Medical Instrumentation (AAMI) が推奨する基準により 5 つのクラスに分類されており、さらに 15 個の詳細なクラスに分類される。評価を簡単化し、15 クラスの中に含まれる少数データクラスを含め正しく分類できるかを評価するため、5 クラス中の 3 クラス N, SVEB, Q から N, L, R, j, A, a, f の計 8 クラスのデータを使用することとした。各クラスのデータ数は表 1 の通りであり、f, j, a が少数データクラスで、中でも a が最もデータ数が少ない。これらのデータに対し、各クラスで 10000 ずつデータを生成して類似度を評価し、全てのクラスで生成データを順に加え、データ数を 10000 に揃えて分類精度を評価した。多数データクラスである N では、元データと生成データの割合が 9:1 になるように生成データを含めた。なお、各クラスの

データを 9:1 の割合で訓練データとテストデータに分け訓練し評価した。

表 1 各クラスのデータ数

クラス	訓練データ	テストデータ	合計
N	67547	7505	75052
L	7268	807	8075
R	6534	725	7259
j	207	22	229
A	2292	254	2546
a	136	14	150
/	6326	702	7028
f	884	98	982

3.2 評価内容

各クラスで生成データから選択し加えたデータが適切かを評価するため、時系列データ同士の類似度を測る動的時間伸縮法 (DTW) を用いる。DTW は 2 つの時系列の各点の距離を全て求め、全パターンのうち最小となる組合せを見つけて類似度とする手法である。提案モデルの分類精度は、データ拡張しない場合をベースラインとして、WGAN、生成器を LSTM にした WGAN、CGAN を組み合わせた AC-WGAN-LSTM でデータ拡張した場合を比較評価する。また、GAN の分類器を ResNet34 とした場合と DeepCNN+BiLSTM-Attention とした場合の比較評価を行う。

3.3 実験結果

3.3.1 DTW 距離

各ラベルにおいて、生成データと真データそれぞれで基準データ[3]との DTW 距離を算出した結果を図 3 に示す。ここでの基準データは、元データを専門家が目視で確認し、クラスごとの形態的特徴をすべて満たすサンプルを選んだものである。DTW は距離が小さいほど基準データに近いことを表しており、ある程度小さくかつ真データの DTW と近いことが望ましい。少数クラス(f,j,a)では提案手法は WGAN と比較し真データに近いまたは同じ値をとる結果となり、多数クラスでも L 以外は真データと近い結果となった。よって、適切にデータ生成が出来たといえる。データ数の多いラベル(L,R)では真データでの DTW との差が比較的大きかった。

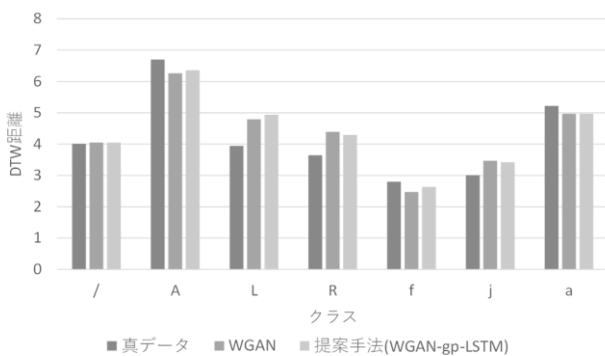


図 3 DTW 距離結果

3.3.2 分類精度

分類精度評価結果を表 2 に示す。データ拡張していない元データのみ(ベースライン)では、多数データクラスでは高精度だが、少数データクラスでは精度が低く、特にデータ数が少ないクラス a は全く分類できない結果となった。これに対し、データ拡張した 3 手法では少数データクラスの j,a で大きく精度が向上し、生成器に LSTM を用いた手法でより精度向上が見られた。WGAN と AC-WGAN の比較では、主に少数データクラスで WGAN の方が精度が高く、AC-WGAN は少数データクラスおよび全体の精度が WGAN よりも低いことから、本データに対しては条件付き GAN は適さなかったといえる。

また、WGAN-LSTM を使用してデータ拡張した場合に、分類器として ResNet34 を使用した場合の少数データクラスの分類精度はそれぞれ 0.597, 0.441, 0.150、全体での精度は 0.958 となり、分類器に DeepCNN+BiLSTM-Attention を用いることで分類精度が向上した。

表 2 分類精度比較結果

ラベル	ベースライン	WGAN	WGAN-LSTM	AC-WGAN-LSTM
/	0.978	0.982	0.982	0.982
A	0.892	0.624	0.882	0.822
L	0.981	0.946	0.942	0.877
N	1.000	0.916	0.999	0.998
R	0.974	0.911	0.931	0.820
f	0.802	0.721	0.791	0.659
j	0.181	0.643	0.653	0.617
a	0.000	0.389	0.426	0.290
全体	0.967	0.972	0.978	0.960
標準偏差	0.387	0.194	0.185	0.218

4. おわりに

本研究では、時系列データにおけるクラス不均衡問題に対処するための手法として、損失関数に EMD を用いペナルティ項を与えた WGAN-gp に時系列データに適した LSTM を生成器として組み込んだ WGAN-gp-with LSTM モデルによるデータ拡張法と、分類精度向上のために DeepCNN-BiLSTM-Attention モデルを使用した分類法を提案した。適切なデータ拡張により少数ラベルで分類精度を大幅に向上させることができ、提案手法によるデータ拡張が不均衡問題解消に寄与することを示した。また DeepCNN-BiLSTM-Attention は ResNet34 と比較し分類性能が高く、ECG データの分類器として有用であることが示された。

一方、少数データクラスは多数データクラスと比較すると分類精度が低いため、一層の精度向上を目指す。

参考文献

- [1] Martin, et al., "Wasserstein GAN", arXiv:1701.07875, 2017.
- [2] Runchuan Li, et al., "Interpretability Analysis of Heartbeat Classification Based on Heartbeat Activity's Global Sequence Features and BiLSTM-Attention Neural Network", IEEE Access, vol. 7, pp. 109870-109883, 2019.
- [3] Edmond, et al., "Arrhythmia Classification Using CGAN-Augmented ECG Signals", arXiv:2202.00569, 2022.