

Denoising autoencoderに基づく 心室期外収縮を含むRR間隔データ補正

Denoising autoencoder-based modification method for
RRI data with premature ventricular contraction

宮谷将太*¹
Shota MIYATANI

藤原幸一*¹
Koichi FUJIWARA

加納学*¹
Manabu KANO

*¹京都大学
Kyoto University

The fluctuation of an RR interval (RRI) on an electrocardiogram (ECG) is called heart rate variability (HRV). Since HRV reflects the activities of the autonomous nervous system, HRV has been used for many kinds of health monitoring systems. However, HRV is easily influenced by arrhythmia, which prevents the precise health monitoring. The present work focuses on premature ventricular contraction (PVC) which is common arrhythmia. To modify RRI data with PVC, the present work proposes a new method based on denoising autoencoder (DAE), referred to as DAE-based RRI modification (DAE-RM). The performance of DAE-RM was evaluated by its application to clinical RRI data which contains artificial PVC (PVC-RRI). The root mean squared error (RMSE) of modified RRI was improved by 83.5 % from PVC-RRI. The result showed that DAE-RM could modify PVC-RRI data appropriately. The proposed DAE-RM has potential for realizing precise health monitoring systems which use HRV analysis.

1. はじめに

心電図 (electrocardiogram; ECG) 波形の最も高いピークを R 波と呼び、隣接する R 波と R 波の間隔を RR 間隔 (RR interval; RRI) と呼ぶ。RRI が時間的に変動する現象を心拍変動 (heart rate variability; HRV) と呼び、HRV は自律神経活動を反映するとされる。そのため、HRV はストレスや眠気を評価する指標として用いられてきた。また、HRV は循環器疾患でも変化するため、循環器疾患の診断にも用いられている [1]。近年、容易に RRI を測定できるウェアラブルデバイスが開発された [2]。このようなウェアラブルデバイスを使用を前提としたてんかん発作の事前予知 [3] や、運転時の眠気検出 [4] などのヘルスマonitoringシステムが提案されている。

RRI データにアーチファクトが混入すると、HRV 指標が大きく変化してヘルスマonitoring性能が低下するため、HRV 解析を行う前にアーチファクトを適切に補正する必要がある。RRI データに混入するアーチファクトの原因は、R 波検出抜けエラーと不整脈の2つに大別される。本研究では後者に注目し、健常者でも起こりうる不整脈である心室期外収縮 (premature ventricular contraction; PVC) を対象とした [5]。

不整脈が含まれる RRI データを用いた HRV 解析における周波数領域指標を補正するアルゴリズムは提案されているが [6]、時間領域指標については触れられていない。本研究では PVC を含む RRI データを補正する手法を提案する。提案手法はノイズ除去を目的とするニューラルネットである denoising autoencoder (DAE) を用いており、本手法を DAE-based RRI modification (DAE-RM) と呼ぶ。本稿ではオープンデータとして公開されている RRI データに人工的な PVC アーチファクトを混入させ、DAE-RM を適用して補正性能を評価する。

2. 心拍変動解析と心室期外収縮

HRV 解析にはさまざまな指標が提案されているが、本節では広く用いられている時間領域指標と周波数領域指標について説明する [1]。また、PVC を含む RRI データを用いたことで生じる HRV への影響について述べる。

2.1 時間領域指標

時間領域指標は、被験者から取得した RRI データから直接計算できる。

- **meanNN** : RRI の平均値。
- **SDNN** : RRI の標準偏差。
- **Total Power (TP)** : RRI の分散。
- **RMSSD** : 隣接する RRI の差の 2 乗平均平方根。
- **NN50** : 隣接する RRI の差が 50 ms を超えた回数。

2.2 周波数領域指標

RRI データは等間隔にサンプリングされていないため、周波数領域指標を計算する前にリサンプリングする必要がある。パワースペクトル密度 (power spectrum density; PSD) はリサンプリング後の RRI データより自己回帰 (auto regression; AR) モデルもしくは Fourier 変換を用いて計算できる。

- **LF** : PSD の低周波 (0.04-0.15 Hz) のパワー。
- **HF** : PSD の高周波 (0.15-0.40 Hz) のパワー。
- **LF/HF** : HF に対する LF の比。

2.3 心室期外収縮

心臓の正常な拍動リズムは洞結節が興奮することで生み出されるが、洞結節以外で興奮が生じると、本来の収縮に先行して心臓が興奮することがある。この不整脈を期外収縮と呼び、特に心室で興奮が生じる期外収縮を PVC と呼ぶ [5]。PVC を

連絡先: 藤原幸一, 京都大学大学院情報学研究所システム科学専攻, 〒606-8501 京都市左京区吉田本町, fujiwara.koichi@i.kyoto-u.ac.jp

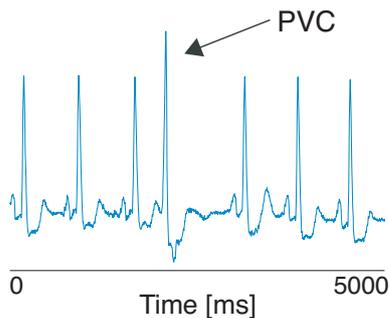


図 1: PVC を含む ECG 波形

含む ECG 波形を図 1 に示す。この図から、PVC が生じたことによって RRI が変化していることがわかる。

Kostis らは、心臓病を持たない健康者 101 名の ECG を 24 時間測定したところ、39 名が少なくとも 1 度は PVC を起こしていたと報告している [7]。また、年齢によって発生率が異なるという報告がされており、PVC を起こした人のうち 11 歳以下の割合は 1% 以下である一方、75 歳以上の割合は 69% を占めている [8]。

PVC が生じると RRI データに大きな変動が生じ、RRI から計算される HRV も影響される。図 2 に PVC アーチファクトを混入させた RRI データ (PVC-RRI) から計算された SDNN と LF/HF を示す。青線と赤線はそれぞれ、元の RRI データから計算された指標と PVC-RRI から計算された指標であることを表し、緑の点線は PVC アーチファクトが混入したタイミングを表す。この図から、PVC アーチファクトを加えた直後から HRV 指標に変化が生じていることがわかる。PVC によって歪められた HRV 指標をその後の解析に用いると、誤った結果を導き出す危険性がある。

3. RRI 補正

本節では、PVC-RRI を補正するアルゴリズムについて述べる。提案するアルゴリズムでは、ノイズ除去を目的とするニューラルネットワークの denoising autoencoder (DAE) を用いる。

3.1 Denoising autoencoder

Autoencoder (AE) はニューラルネットワークを用いた次元圧縮、特徴抽出手法である [9]。AE は出力を入力とできるだけ等しくするため、入力と出力の再構築誤差を最も小さくするように学習を行う。このとき、中間層と出力層において活性化関数を恒等写像とすると、AE は代表的な次元圧縮手法である主成分分析 (principal component analysis; PCA) と一致する。次元圧縮された特徴を得るため、隠れ層のユニット数は入力変数の

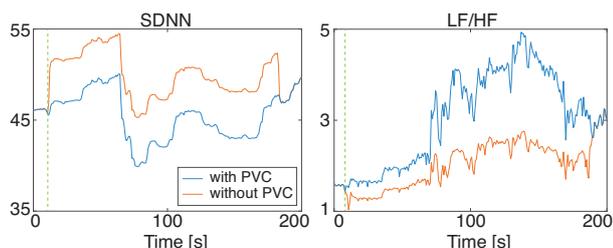


図 2: PVC が HRV 指標に与える影響: SDNN(左図), LF/HF(右図)

Algorithm 1 DAE-RM

```

1: while do
2:   Collect the newly measured  $t$ th RRI  $x_t$ .
3:   Store  $x_t$  to the buffer in the FIFO manner.
4:   if PVC detection then
5:     Wait the next  $t+1$ th to  $t+T+P-1$ th RRI  $x_{t+1}, \dots, x_{t+T-1}, \dots, x_{t+T+P-1}$ .
6:     Extract the previous  $P$  RRI  $x_{t-P}, \dots, x_{t-1}$  from the buffer.
7:     Construct the RRI subsequence to be modified:
            $\mathbf{x}_s = [x_{t-P}, \dots, x_t, \dots, x_{t+T-1}, \dots, x_{t+T+P-1}]$ .
8:     Calculate the mean of  $\mathbf{x}_s$ ,  $\bar{\mathbf{x}}_s$ .
9:      $\mathbf{x}_s = \mathbf{x}_s - \bar{\mathbf{x}}_s$ .
10:    Get the modified RRI subsequence  $\hat{\mathbf{x}}_s$  by inputting  $\mathbf{x}_s$  to the trained DAE.
11:     $\hat{\mathbf{x}}_s = \hat{\mathbf{x}}_s + \bar{\mathbf{x}}_s$ .
12:     $d = \sum \hat{\mathbf{x}}_s - \sum \mathbf{x}_s$ .
13:    Take the last element of  $\mathbf{x}_s$ ,  $\hat{x}_s^e$ .
14:     $\hat{x}_s^e = \hat{x}_s^e - d$ .
15:    Replace  $\mathbf{x}_s$  to  $\hat{\mathbf{x}}_s$ .
16:  else
17:    Wait until the next RRI data  $x_{t+1}$  is measured.
18:  end if
19: end while

```

数よりも小さくするべきであるが、正則化項を導入することで隠れ層のユニット数を入力変数の数より大きくすることができる。この手法を sparse AE (SAE) と呼ぶ [10]。

DAE は AE と同じ構造を持つニューラルネットワークであるが、学習時の入力にノイズを加え、ノイズを加える前の入力と同様の出力を得よう学習を行う [11]。ノイズを加えて学習を行うことから、DAE はノイズ除去能力を有すると考えられる。本研究では、SAE と DAE を組み合わせて用いた。

3.2 DAE-RM

PVC が混入したことによる RRI データの変化はアーチファクトとみなすことができるので、DAE によって PVC アーチファクトを除去できる可能性がある。この DAE に基づく手法を DAE-based RRI modification (DAE-RM) と呼ぶ。

提案する DAE-RM のアルゴリズムを Algorithm 1 に示す。ここで、DAE は RRI 補正を行う前にすでに学習済みであるとする。ステップ 3 で first-in-first-out (FIFO) にて、新たに測定された RRI をバッファに記録する。RRI データに PVC が検出された場合、ステップ 5-15 で DAE による補正を行なう。ステップ 5-7 にて、DAE によって補正する RRI の部分データ \mathbf{x}_s を構築する。ここで T は PVC によって変化した RRI の要素の数を表しており、 $T=2$ のときは PVC は単発性である。また、 P は DAE による補正幅を表すパラメータであり、 T 拍の前後 P 拍を DAE によって補正する。これは、DAE で補正を行うために PVC 前後の RRI データが必要なためである。ステップ 9 で DAE 適用前に \mathbf{x}_s の中心化を行い、ステップ 11 で復元している。 \mathbf{x}_s の時間合計が補正の前後で変化しないようにするため、補正による時間合計の変化を補う必要がある。そこでステップ 12-14 にて、 \mathbf{x}_s の最後の要素で補正前後の変化を調整している。

4. ケーススタディ

本節では、PVC アーチファクトを加えた実際の RRI データに対し、DAE-RM を適用した結果を示す。

4.1 データセット

ケーススタディには PhysioNet の正常洞調律データベース (normal sinus rhythm database; NSRDB) を用いた [12]. NSRDB には成人 18 名の ECG と RRI のデータが含まれており、これらを被験者 A - R とする。被験者は 26 歳から 45 歳までの 5 人の男性 (平均 33.8, 標準偏差 7.7) と、20 歳から 50 歳までの 13 名の女性 (平均 35.8, 標準偏差 7.7) で構成され、その全員が不整脈でないことと診断されている。データベースにある RRI データのいくつかには明らかなアーチファクトが含まれており、これらのアーチファクトは DAE-RM の性能を評価する妨げとなるため、これらを除いた。その結果、18 名の被験者から RRI データのエピソードが 166 個作成され、エピソードの合計時間は 375 時間となった。PVC アーチファクトはエピソードのランダムな位置に加え、本ケーススタディではその位置を既知であるものとした。

4.2 DAE の学習

DAE の学習には被験者 A から得られたエピソードを用いた。中間層と出力層の活性化関数にはそれぞれ、シグモイド関数と恒等写像を用いた。DAE のパラメータは被験者 B-F から得られたエピソードを用いて決定し、DAE によって補正する要素の数が 4, 中間層のユニット数が 20, 最大試行回数が 2000 となった。つまり、Algorithm 1 において $T = 2$, $P = 1$ となった。また、パラメータ決定時に L^2 正則化項を用いてスパース性を導入した。そのため、ユニットを結合するほぼすべての重みが 0 となっている。

4.3 RRI 補正

被験者 G-R から得られたすべてのエピソードを用いて DAE-RM の性能を検証した。なお、PVC-RRI データの作成と DAE-RM による補正は、加えたアーチファクトの位置に補正性能が依存することを防ぐため、5 回の試行を行ってその平均値を結果としている。図 3 は DAE-RM を被験者 M のあるエピソードに対して適用した結果である。青線、赤線、緑線はそれぞれ、元の RRI データ、PVC-RRI データ、PVC-RRI データを DAE-RM によって補正した RRI データを表す。この図から、DAE-RM による補正後の RRI データが元の RRI データと非常に近い値をとっていることがわかる。元の RRI データと PVC-RRI データの平方平均二乗誤差 (root mean squared error; RMSE) に対する、元の RRI データと補正後の RRI データの RMSE の改善率は 83.5% であった。

また、図 3 に示したそれぞれの RRI データから HRV 指標を計算した結果を図 4 に示す。これらの指標における RMSE の改善率は、meanNN: 81.6%, SDNN: 98.3%, Total Power: 98.4%, RMSSD: 97.5%, NN50: 68.3%, LF: 86.8%, HF:

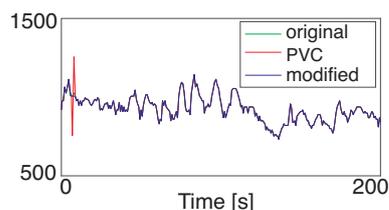


図 3: 被験者 M の補正前後の RRI データ

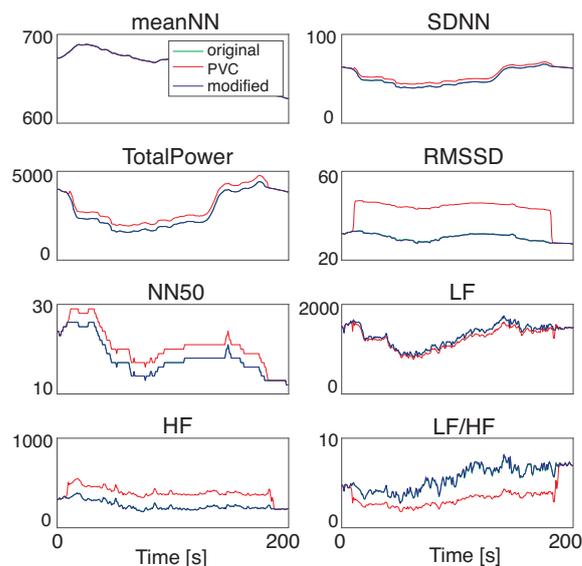


図 4: 被験者 M の補正前後の HRV 指標

95.1%, LF/HF: 91.7% となった。この結果から、PVC が HRV 解析に与える影響を DAE-RM によって抑えられていることがわかる。

4.4 考察

DAE による RRI 補正の性能を他の回帰手法と比較する。今回は、partial least squares (PLS) と、locally weighted PLS (LW-PLS) を比較の対象とした。PLS は広く使われている線形回帰手法であり、入力変数より少ない潜在変数を用いることで多重共線性の問題を回避できる [13]. LW-PLS は PLS を拡張した手法で、すでに得られているデータセットのサンプルとクエリの類似度を重みとして、クエリにおける入出力関係を最もよく表現するサンプルを用いて局所的な PLS モデルを構築する [14].

DAE-RM, PLS, LW-PLS を用いて RRI 補正を行った結果を図 5, 6 に示す。縦軸には RRI と HRV の RMSE の改善率を用いた。これらの箱ひげ図から提案する DAE-RM が 2 つの手法と比較して、最も良い性能であることが示された。

以上の結果から、提案手法の DAE-RM は PVC が混入した RRI データの補正に有用であることが示された。また、DAE-RM によって HRV を用いたヘルスマニタリングをより正確に行える可能性が示された。

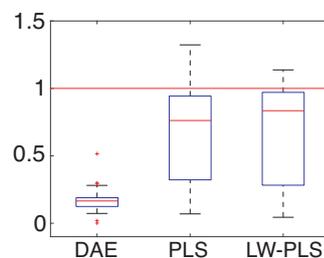


図 5: RRI の RMSE 改善率

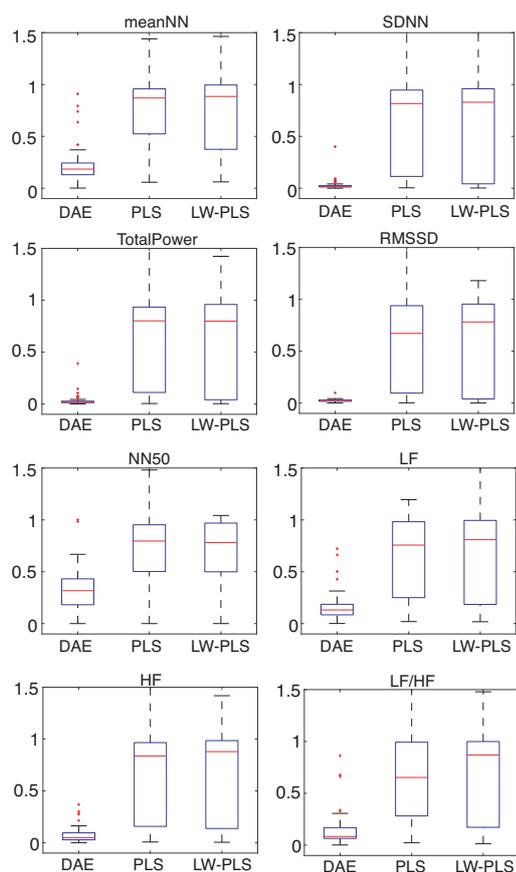


図 6: HRV 指標の RMSE 改善率

5. まとめ

本研究では、DAE を用いた PVC を含む RRI データの補正手法を提案した。PLS や LW-PLS などと比較して、提案する DAE-RM が PVC-RRI の補正に最も適していることが示された。

ケーススタディでは PVC が生じたタイミングが既知であるとしていたが、実用するためには PVC が生じたタイミングを検出しなければならない。今後の課題として、RRI データに含まれる PVC を検出する手法を開発する必要がある。また、RRI データに加わりうるもうひとつのアーチファクトである R 波検出抜けエラーについても、提案する DAE-RM が適用できるかどうか検証する。

参考文献

- [1] Task Force of the European Society of Cardiology and the North American Society of Pacing and Electrophysiology, “Heart rate variability: Standards of measurement, physiological interpretation, and clinical use,” *Circulation*, vol. 80, pp. 1043–1065, 1996.
- [2] T. Yamakawa *et al.*, “Development of a wearable hrv telemetry system to be operated by non-experts in daily life,” in *2013 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference*, oct 2013, pp. 1–4.

- [3] K. Fujiwara *et al.*, “Epileptic seizure prediction based on multivariate statistical process control of heart rate variability features,” *IEEE Transactions on Biomedical Engineering*, vol. 63, no. 6, pp. 1321–1332, jun 2016.
- [4] E. Abe *et al.*, “Development of drowsiness detection method by integrating heart rate variability analysis and multivariate statistical process control,” *SICE Journal of Control, Measurement, and System Integration*, vol. 9, no. 1, pp. 10–17, 2016.
- [5] F. C. Messineo, “Ventricular ectopic activity: Prevalence and risk,” *The American Journal of Cardiology*, vol. 64, no. 20, pp. J53 – J56, 1989.
- [6] J. Mateo and P. Laguna, “Analysis of heart rate variability in the presence of ectopic beats using the heart timing signal,” *IEEE Transactions on Biomedical Engineering*, vol. 50, no. 3, pp. 334–343, March 2003.
- [7] J. B. Kostis *et al.*, “Premature ventricular complexes in the absence of identifiable heart disease.” *Circulation*, vol. 63, no. 6, pp. 1351–1356, 1981.
- [8] Y. M. Cha *et al.*, “Premature ventricular contraction-induced cardiomyopathy,” *Circ. Arrhythm. Electrophysiol.*, vol. 5, no. 1, pp. 229–236, 2012.
- [9] P. Baldi and K. Hornik, “Neural networks and principal component analysis: Learning from examples without local minima,” *Neural Networks*, vol. 2, no. 1, pp. 53 – 58, 1989.
- [10] W. Sun *et al.*, “A sparse auto-encoder-based deep neural network approach for induction motor faults classification,” *Measurement*, vol. 89, no. 7, pp. 171–178, 2016.
- [11] P. Vincent *et al.*, “Extracting and composing robust features with denoising autoencoders,” in *Proceedings of the 25th International Conference on Machine Learning*, ser. ICML ’08. New York, NY, USA: ACM, 2008, pp. 1096–1103.
- [12] M. Costa *et al.*, “Physionet: an nih research resource for complex signals,” *Journal of Electrocardiology*, vol. 36, pp. 139 – 144, 2003.
- [13] P. Geladi and B. R. Kowalski, “Partial least-squares regression: a tutorial,” *Analytica Chimica Acta*, vol. 185, pp. 1 – 17, 1986.
- [14] S. Kim *et al.*, “Development of soft-sensor using locally weighted pls with adaptive similarity measure,” *Chemometrics and Intelligent Laboratory Systems*, vol. 124, pp. 43 – 49, 2013.