Denoising autoencoder に基づく 心房期外収縮を含む RR 間隔データ補正 Denoising autoencoder-based modification method for RRI data with premature atrial contraction

宫谷将太*¹ 藤原幸一*² 加納学*¹ Shota MIYATANI Koichi FUJIWARA Manabu KANO

> *¹京都大学 *²名古屋大学 Kyoto University Nagoya 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 analysis has been used for health monitoring systems. However, the performance of health monitoring systems using HRV features is easily deteriorated by arrhythmias. The present work focuses on premature atrial contraction (PAC) that many healthy people have. To modify RRI data with PAC, the present work proposes a new method based on a denoising autoencoder (DAE), referred to as DAE-based RRI modification (DAE-RM). The proposed method aims to correct the disturbed RRI data by regarding PAC as artifacts. The performance of DAE-RM was evaluated by its application to RRI data which contains artificial PAC (PAC-RRI). The result showed that DAE-RM successfully modified PAC-RRI data. The root means squared error (RMSE) of the modified RRI was improved by 27.4% from the PAC-RRI. 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に使用 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] などのヘルスモニタリングシステムが提案されている.

アーチファクトが RRI データに混入した場合, HRV 指標 が大きく変化してヘルスモニタリング性能が低下する. アーチ ファクトには心臓由来,または R 波検出アルゴリズム由来の ものがある.前者は不整脈などによるアーチファクトで,後者 は ECG における R 波を検出できないことによるアーチファ クトである. ヘルスモニタリングシステムを実現するために は, HRV 解析を行う前にこれらのアーチファクトを適切に補 正する必要がある.

このような背景から,健常者にも起こりうる珍しくない不 整脈である心室期外収縮 (premature ventricular contraction; PVC) を対象とする手法が提案されている [5].本研究では PVC と同様に健常者にも生じうる心房期外収縮 (premature atrial contraction; PAC) を対象とした [6]. PAC などの不整 脈が含まれる RRI データに対して,LS ピリオドグラムを用い て HRV 指標の周波数領域指標を補正する手法は提案されてい る [7].一方,HRV 解析を用いた多くのアプリケーションでは HRV 指標の時間領域指標を併用しているため,この手法のみ でアーチファクトの影響を除去し,適切な HRV 解析を行うこ とはできない.本研究では PAC 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 PAC 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. 心拍変動解析と心房期外収縮

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,PAC について説明し,PAC が HRV 解 析に与える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.

連絡先: 藤原幸一,名古屋大学工学研究科,〒 464-8602 名 古屋市千種区不老町, fujiwara.koichi@material.nagoyau.ac.jp



図 2: PVC を含む ECG 波形

2.3 心房期外収縮

心臓の正常な拍動リズムは洞結節の興奮によって生じるが, 洞結節以外での興奮が本来の収縮に先行することがある.この 現象は期外収縮と呼ばれる不整脈の一種で,特に心房で興奮が 生じる期外収縮を PAC と呼ぶ [8]. PAC を含む ECG 波形を 図1に示す.この図から, PAC が生じたことによって RRI が 変化していることがわかる.

次に, PVC を含む ECG 波形を図 2 に示す. 図 1, 2 を比 較すると, どちらの場合でも RRI が変化しているとわかる. PVC では発生直後の RRI が比較的大きくなっているのに対 し, PAC では発生直後の RRI は通常と変わらないことがわ かる.

David らは無作為に選ばれた 50 歳以上の被験者 1742 名の ECG をホルター心電図で測定したところ,1 度も PAC を起 こさなかった被験者は 18 名であったと報告している [6].ま た,同論文では1時間あたりに起きた PAC の回数は年齢とと もに増加することも報告されている.

PAC 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 も大きな影響を受ける. 図 3 に PAC アー チファクトを混入させた RRI データ (PAC-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 PAC-RRI から計算された 指標であることを表し, 緑線は PAC 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, PAC 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, PAC 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. PAC によって大きく変化した HRV 指標を用いて解析を行う と, HRV 解析に基づくアプリケーションの性能は大きく低下 する.

3. RRI 補正

本節では、PAC-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 ニューラルネットの denoising autoencoder (DAE) を用いる.

3.1 Denoising autoencoder

Autoencoder (AE) はニューラルネットを用いた次元圧縮, 特徴抽出手法である [9]. AE では出力が入力と等しくなるよ うに学習を行い,出力を再現できる中間層を獲得する.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.

DAE は AE と同じ構造を持つニューラルネットである. DAE はノイズを加えたデータを入力とし、ノイズを加える前の入力 と同様の出力を得るよう学習を行う [10]. このように学習を 行うことから、DAE はノイズを除去する能力があるとされて いる.

3.2 DAE-based RRI modification

PAC 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.そのため,DAE によって PAC アーチファクトを除去できると考えられる.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 PAC が 検出された場合,ステップ 5-16 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 x_s を構築する. ここでTは PAC によって変化した RRIの 要素の数を表しており、T = 2のとき単発性 PAC を表す.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 PAC 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 x。の中心化を行い, ステップ 11 で復元している. 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にて補正前後の要素の合計値を計算し、ス テップ15にて x。以降の D 個の要素に差分を足し合わせるこ とにより埋め合わせを行う.

4. ケーススタディ

本節では、PAC 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.



図 3: PAC が HRV 指標に与える影響: SDNN(左図), LF/HF(右図)

2N3-J-13-01

Algorithm 1 DAE-RM

1: while do

- 2: Collect the newly measured tth RRI x_t .
- 3: Store x_t to the buffer in the FIFO manner.
- 4: **if** PAC detection **then**
- 5: Wait the next t+1th to t+T+P-1th RRI $x_{t+1}, \cdots, x_{t+T-1}, \cdots, x_{t+T+P-1}$.
- 6: Extract the previous P RRI x_{t-P}, \dots, x_{t-1} from the buffer.
- 7: Construct the RRI subsequence to be modified: $\boldsymbol{x}_s = [x_{t-P}, \cdots, x_t, \cdots, x_{t+T-1}, \cdots, x_{t+T+P-1}].$
- 8: Calculate the mean of $\boldsymbol{x}_s, \, \bar{\boldsymbol{x}}_s.$
- 9: $x_s = x_s \bar{x}_s$.
- 10: Get the modified RRI subsequence \hat{x}_s by inputting x_s to the trained DAE.
- 11: $\hat{\boldsymbol{x}}_s = \hat{\boldsymbol{x}}_s + \bar{\boldsymbol{x}}_s.$
- 12: $d = \sum \hat{\boldsymbol{x}}_s \sum \boldsymbol{x}_s.$
- 13: Replace \boldsymbol{x}_s to $\hat{\boldsymbol{x}}_s$.
- 14: Construct the RRI subsequence to be compensated:

$$\boldsymbol{x}_D = [x_{t+T+P}, \cdots, x_{t+T+P+D-1}]$$

- 15: $x_D = x_D (d/D)\mathbf{1}_D.$
- 16: else
- 17: Wait until the next RRI data x_{t+1} is measured.
- 18: end if

19: end while

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 [11]. 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, その全員が循環器疾患をもたないと診断されている.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,これらを除去した.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.PAC 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, Rectified Linear Unit (ReLU) 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 2 となった. つまり, Algorithm 1 において T = 2, P = 1 となった.

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, PAC-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,10回の試行を行ってその平均値 を結果としている.図4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



図 4: 被験者 M の補正前後の HRV 指標

ぞれ,正常 RRI データ,PAC-RRI データ,PAC-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 PAC-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 27.4 %であった.また,HRV 指標に おける RMSE の改善率は,meanNN: 0.1%,SDNN: 24.8%, TP: 22.7%, RMSSD: 70.8%, NN50: 34.0%, LF: 22.7%, HF: 28.2%, LF/HF: 30.0%となった.この結果から,PAC 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 [12]. 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 [13].

DAE-RM, PLS, LW-PLS を用いて RRI 補正を行った結 果を図 5 に示す. 縦軸には RRI と HRV の RMSE の改善率 を用いた.提案手法を PVC に適用した際には DAE が最も高 い精度であったが, PAC に適用した場合, PLS が最も良い性 能であることがわかる [5]. この要因は PAC と PVC によって 影響を受ける RRI の要素数であると考えられる. PVC では 2 要素が変化するのに対し, PAC では 1 要素しか変化しないた め, DAE が 1 要素のみの変化の特徴をうまく学習できなかっ た可能性がある.

5. まとめ

本研究では,DAE を用いた PAC を含む RRI データの補正 手法を提案した.PVC を含む RRI データに提案手法を適用 した際には DAE が最も高い精度であったが [5],PAC に対し ては PLS が最も高い精度であった.

実用化に向けて考えると、PAC と PVC のそれぞれに適合



図 5: RRI と HRV 指標の RMSE 改善率

した DAE を作成しているため,補正前にこれらの不整脈の分 類を行う必要がある.不整脈を識別するアルゴリズムは様々な 論文で提案されているが,これらはオフラインでの解析を前 提としているため,ウェアラブルデバイスでのリアルタイム解 析においての使用を意図しておらず,今後検討を進める必要が ある.

今後は、PAC や PVC, R 波抜けの検出と分類を行い、そ れぞれを適した手法で補正することにより RRI データに混入 したアーチファクトを統合的に扱う手法の提案を目指す.

謝辞

本研究の一部は,科研費基盤 A #17H00872, AMED 先端 計測プログラム #171122, JST さきがけ #JPMJPR1859, セコム科学技術振興財団,住友電工グループ社会貢献基金から 助成を受けて実施された.

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, pp. 1–4, oct 2013.
- [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] S. Miyatani, et al. Deniosing autoencoder-based modification of rri data with premature ventricular contraction for precise heart rate variability analysis. In 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 5018–5021, July 2018.
- [6] C. David, et al. Premature atrial contractions in the general population. *Circulation*, Vol. 126, No. 19, pp. 2302–2308, 2012.
- [7] 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 En*gineering, Vol. 50, No. 3, pp. 334–343, March 2003.
- [8] F. C. Messineo. Ventricular ectopic activity: Prevalence and risk. *The American Journal of Cardiology*, Vol. 64, No. 20, pp. J53 – J56, 1989.
- [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] P. Vincent, et al. Extracting and composing robust features with denoising autoencoders. In *Proceedings of* the 25th International Conference on Machine Learning, ICML '08, pp. 1096–1103, New York, NY, USA, 2008. ACM.
- [11] M. Costa, et al. Physionet: an nih research resource for complex signals. *Journal of Electrocardiology*, Vol. 36, pp. 139 – 144, 2003.
- [12] P. Geladi and B. R. Kowalski. Partial least-squares regression: a tutorial. Analytica Chimica Acta, Vol. 185, pp. 1 – 17, 1986.
- [13] 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.