

推薦論文

Stacked Convolutional Denoising Autoencoders を用いた2誘導心電図からの特徴抽出および不整脈分類

高橋 柊^{1,†1} 落合 桂一^{1,a)} 深澤 佑介¹

受付日 2018年3月1日, 採録日 2018年9月7日

概要: さまざまなモノおよびコトをインターネットに接続することで, ログ収集および相互制御を行う Internet of Things (IoT) に注目が集まっている. IoT の活用により, 今までセンシングが困難であった情報がリアルタイムに取得可能となることが期待されている. 1つの例として心電計測があげられる. 心電図 (ECG) をリアルタイムに解析することができれば, IoT デバイスの活用によりリアルタイムに不整脈などを検出することが可能となる. 本研究では, Stacked Convolutional Denoising Autoencoders (SCDAE) を用いた, ECG 波形からの高レベルな特徴抽出を提案する. また, 事前学習した SCDAE の構造および重みを抽出し, 全結合層を追加した分類器を再学習する不整脈分類手法を提案する. 未知の ECG 波形からの不整脈分類において, 提案手法が既存手法 (Accuracy: 92.7%) に対し高精度 (Accuracy: 95.3%) であることを示す.

キーワード: Stacked Denoising Autoencoders (SDA), Convolutional neural network (CNN), 不整脈検出, 心電図 (ECG)

Feature Extraction and Arrhythmia Classification from 2-lead ECG using Stacked 1D-convolutional Denoising Autoencoders

SHU TAKAHASHI^{1,†1} KEIICHI OCHIAI^{1,a)} YUSUKE FUKAZAWA¹

Received: March 1, 2018, Accepted: September 7, 2018

Abstract: Internet of Things (IoT) which connects various kinds of things via internet each other and gathers logs has much attention. It is expected for utilizing IoT to make it possible to acquire information which was conventionally difficult to sense in real-time. One example is electrocardiography. If we can analyze electrocardiogram (ECG) in real time, it becomes possible to detect arrhythmia in real time by using the IoT device. In this paper, we propose high level feature extraction from ECG waveform using Stacked Convolutional Denoising Autoencoders (SCDAE). ECG classifier is built by combining the architecture and weights of SCDAE with fully connected layer. Evaluation results show that the proposed method (Accuracy: 95.3%) outperforms the existing works (Accuracy: 92.7%) for unseen ECG beats.

Keywords: Stacked Denoising Autoencoders (SDA), Convolutional neural network (CNN), arrhythmia detection, electrocardiogram (ECG)

1. はじめに

近年, さまざまなモノおよびコトをインターネットに接続することで, ログ収集および相互制御を行う Internet of

Things (以下, IoT) に注目が集まっている [1]. IoT の活用により, 今までセンシングが困難であった情報がリアルタイムに取得可能となることが期待されている. 高河原ら [2] は服型ウェアラブルデバイス「hitoe」を用いることで, 装着者の心電波形を検出する手法を提案している. 服

¹ 株式会社 NTT ドコモ
NTT DOCOMO, INC., Minato, Tokyo 107-0052, Japan

^{†1} 現在, SAS Institute Japan 株式会社
Presently with SAS Institute Japan Ltd.

^{a)} ochiaike@nttdocomo.com

本論文の内容は 2017 年 6 月の第 83 回 MBL 研究発表会にて報告され, 同研究会主査により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である.

型デバイスおよび IoT の活用により、リアルタイムに心電波形を検出することが可能となる。

本研究は、心電図 (ECG; Electrocardiogram) からの不整脈自動検出を目的とする。ECG をリアルタイムに分析することができれば、IoT の活用によりリアルタイムなストレス度合い、不整脈検出が可能となる [3]。ECG からの不整脈検出には以下のような問題が存在する。

観測対象による波形変化

ECG 波形は観測対象者や観測時間によって変化する。そのため、観測対象に対しロバストな不整脈の検出を行うことは困難である。

心拍変動による波形変化

ECG 波形は観測対象者のストレス状態や興奮、運動などの生理学および精神的変化によって変化する。そのため、測定状態に対しロバストな不整脈の検出を行うことは困難である。

観測ノイズ

ECG 波形には観測ノイズが含まれている。そのため、分析前には適切なノイズ除去が必要である。

観測対象および心拍変動による波形変動や観測ノイズに対しロバストな不整脈検出が可能となれば、人や観測状態を選ばずリアルタイムに不整脈検出が可能となる。本研究では、Stacked Convolutional Denoising Autoencoders (以下、SCDAE) を用いた ECG からの不整脈分類手法を提案する。観測対象および心拍変動による波形変動に対して、SCDAE の畳み込み層が高レベルの特徴抽出を行い、プーリング層が特徴の位置普遍性を獲得することが期待できる。また、SCDAE を事前学習 (pre-training) をしたのち、SCDAE のエンコーダ部分に全結合のニューラルネットワークを追加し再学習 (fine-tuning) することで、観測ノイズに対し頑強な分類モデルの構築が期待できる。

本研究の貢献は以下のとおりである。

- ECG からの不整脈分類において問題となる心拍変化および観測ノイズ問題に対し、SCDAE を用いた高レベルの特徴抽出について提案した。
- 事前学習された SCDAE に全結合層を追加することで、未知のユーザについて高精度な分類能力を持つ分類器を提案した。

本論文では、次章にて関連研究について述べ本研究との差分について説明する。次に、3 章にて提案手法の詳細を説明する。4 章では実データを用いた実験を行い、既存手法と提案手法の精度について検証する。最後に 5 章にて本研究のまとめおよび今後の課題について述べる。

2. 関連研究

2.1 不整脈検出の流れと関連研究

ECG からの不整脈検出については、多くの手法が提案されている。図 1 に 2 誘導 ECG の概要を示す。ECG は心臓

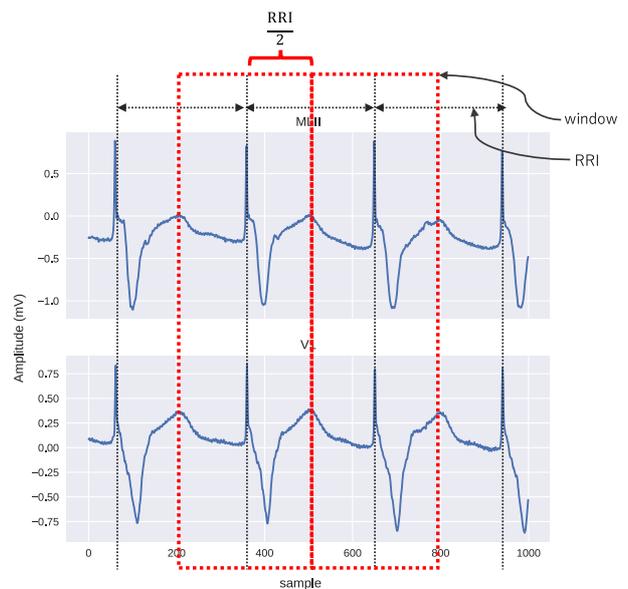


図 1 ECG の概要

Fig. 1 Example of ECG.

の電気的な活動を記録している。2 誘導 ECG では、一般に MLII および V1 の 2 種類の波形が観測され、各波形の相互変化を観察することで、不整脈の診断が可能となる。ECG 波形は、心拍間隔 (以下、RRI) を基準に分割され、window ごとに不整脈であるか否かが決定される。そのため、ECG 分類には各 window から有効な特徴を抽出することが求められる。

ECG 波形からの特徴抽出にはウェーブレット変換をもちいた研究がある。Srivastava ら [4] は離散ウェーブレット変換 (DWT; Discrete wavelet transform) を用い、ECG 波形の周波数特性を抽出したのち、fuzzy hybrid neural network により波形を分類する手法を提案している。DWT を用いたスペクトル解析により圧縮された特徴が、ECG 波形分類に有効であることを示している。Tang ら [5] は ECG 波形よりピーク点 (P, Q, R, S および T 点) を検出し、各ピーク点間の距離および RS により次元削減した特徴を用い quantum neural networks (QNN) により波形を分類する手法について提案している。しかし、これらの手法はウェーブレット変換により抽出された特徴を用いるため、観測対象による波形変化が存在するという ECG の特性上、未知の観測対象から得られた ECG データを分類することは困難である。

Osowski ら [6] は観測対象によって変化する ECG 波形からラベルごとに共通した特徴を抽出するため、higher order statistics (HOS) を用いた特徴抽出について検討している。HOS を用いることで観測対象が異なる ECG 波形についても、ラベルごとに共通した特徴が抽出可能であることを示している。

2.2 深層学習による不整脈検出の関連研究

Kiranyaz ら [7] は、不整脈検出の対象の患者の ECG をト

レーニングデータに用いた patient-specific な不整脈検出モデルを提案した。このモデルでは、1次元の Convolutional Neural Networks (以下, CNN) を利用して不整脈を検出する。評価では、特定の種別 (4.1 節で後述するラベル S および V) の不整脈の検出性能で評価を行っている。Zubair ら [8] は、Kiranyaz らと同様に CNN を用いることで、未知の観測対象における ECG からの不整脈検出について検討している。CNN を用いることで、新たに観測された ECG 波形について高精度に不整脈検出が可能であることを示している。Rahhal ら [9] は、オンラインでの不整脈検出を目的に能動学習により不整脈検出のモデルを学習する枠組みを提案し、その中で Stacked Denoising Autoencoders (以下, SDAE) を用いたモデルを提案した。Rajpurkar ら [10] は、iRhythm Technologies^{*1} の Zio Patch monitor を利用し約 30,000 人の不整脈患者の 1 誘導 ECG データセットを構築した。これは、不整脈検出の既存研究で広く使われている 2 誘導 ECG データである MIT-BIH データベース (48 人 30 分間の ECG データ。詳細は 4.1 節を参照)^{*2} より大規模である。このデータを利用し、34 層の CNN モデルを学習し 14 種類の不整脈の種別に分類した。Pourbabaee ら [11] は、発作性心房細動 (Paroxysmal Atrial Fibrillation, PAF) の検出を対象に CNN を特徴抽出に利用し、得られた特徴量を KNN や SVM によって分類することで PAF を検出する手法を提案した。この研究では PAF の検出に特化しており、複数種類の不整脈検出は評価されていない。

本研究では SCDAE を用いた ECG からの特徴抽出および不整脈分類について検討する。既存研究においても、CNN や SDAE を用いた ECG 波形の分類手法が提案されているが、CNN に Denoising Autoencoder (以下, DAE) を組み合わせた SCDAE による不整脈分類は提案されていない。SCDAE を用いることで、未知のユーザやノイズに対しより頑強な特徴を抽出する。また、学習された重みを用いた分類器を構築することで不整脈分類を行う。関連研究と比較し、未知のデータに対する不整脈分類精度が高精度であることを示す。

3. 提案手法

本研究では、SCDAE を用いた ECG からの特徴抽出および不整脈分類について検討する。提案手法は以下の 2 つのステップから構成される。なお、本研究における未知ユーザは、トレーニングデータに含まれないユーザのことと定義する。

i) SCDAE による特徴抽出 (pre-training)

各波形からノイズを除去する SCDAE の事前学習 (pre-training) を行う。SCDAE により、未知のユーザおよびノイズに対して頑強な特徴抽出が期待できる。

ii) 分類器の構築 (fine-tuning)

SCDAE の学習により得られたモデルより、エンコーダ部分を抽出し全結合層を追加した分類器を構築する。SCDAE の事前学習により得られた重みを利用し分類器の fine-tuning を行うことで、高精度な分類器の構築が期待できる。

3.1 SCDAE による特徴抽出 (pre-training)

Autoencoder (以下, AE) はニューラルネットワークを使用した次元圧縮アルゴリズムである [12]。入力データと出力データが同じようになるようニューラルネットワークを学習させることで、多量の特徴量から入力データの説明に有効な圧縮された特徴量の抽出が期待できる。入力 $x \in \mathbb{R}$ に対し、エンコーダ $y = f_{\theta}(x)$ とデコーダ $g_{\theta'}(y)$ 、学習すべき重み θ, θ' および損失関数を L としたとき、AE は式 (1) の最適化問題として定義される。

$$\min_{\theta, \theta'} \frac{1}{2} \sum_{i=1}^n L(x_i, g(f(x_i))) \quad (1)$$

ただし、活性化関数を σ 、学習により求められる重みを W 、バイアスを b 、 $\theta = \{W, b\}$ としたとき、 $f_{\theta}(x)$ は式 (2)、 $g_{\theta'}(y)$ は式 (3) として定義される。

$$f_{\theta}(x) = \sigma(W_x + b) \quad (2)$$

$$g_{\theta'}(y) = \sigma(W'_x + b') \quad (3)$$

Vincent ら [13] は AE の入力ベクトルにノイズを加えることで、AE と比較しより汎化された特徴の抽出を行う DAE について提案している。図 2 に DAE の例を示す。DAE では入力 $X = x$ についての破壊プロセス (corruption)

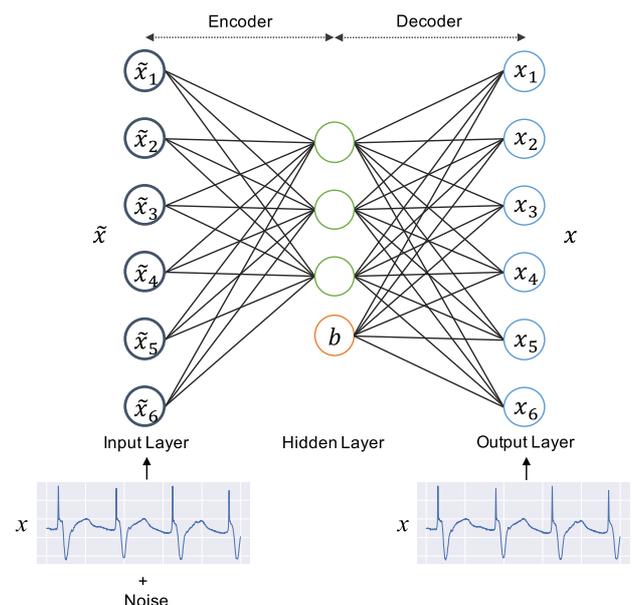


図 2 DAE の例: x にノイズを加えた \tilde{x} を入力し x を復元する
 Fig. 2 Example of DAE: Recovering x from \tilde{x} which is added noise.

^{*1} <http://irhythmtech.com/>
^{*2} <https://physionet.org/physiobank/database/mitdb/>

process) $C(\tilde{X}|X)$ から \tilde{X} をサンプリングすることで、入力ベクトル x を \tilde{x} に破損させる。破損させた \tilde{x} を入力とし、AE と同様に x を復元するようなニューラルネットワークを学習させることで、AE と比較しより有効な特徴量の抽出を試みる。入力データ X を生成する分布を $P(X)$ としたとき、DAE は式 (4) の期待値最適化問題として定義される。

$$\min_{\theta, \theta'} \mathbb{E}_{X \sim P(X), \tilde{X} \sim C(\tilde{X}|X)} L(X, g(f(\tilde{X}))) \quad (4)$$

近年、画像認識、言語処理などさまざまな分野において CNN が高い認識精度を示している [14], [15], [16]。CNN では、畳み込み層 (Convolutional layer) およびプーリング層 (Pooling layer) から構成されるニューラルネットワークである。畳み込み層を用いることで入力データに出現するパターンを認識し、プーリング層により入力データにおけるパターン出現位置について頑健なモデルを生成することが可能となる [17]。Masci ら [18] は AE のエンコーダ層および中間層に CNN を利用した Convolutional Auto Encoder (以下、CAE) を提案している。CAE より学習された重みを用いた分類器が CNN と比較しよりよい分類精度であることを示している。Du ら [19] は CAE を多層化し、入力データにノイズを付加した SCDAE を提案している。既存の特徴抽出手法と比較し、SCDAE がより汎化した特徴を抽出することを示している。

本研究では、DAE のエンコーダ層とデコーダ層に畳み込み層およびプーリング層を持つ SCDAE により ECG から特徴抽出を行う。ECG 波形からの不整脈検出には、観測対象および心拍変動による波形変化と観測ノイズ問題が存在する。畳み込み層により高レベルの特徴認識を行い、プーリング層により特徴の位置不変性を獲得することができれば、観測対象および心拍変化に対し頑強な特徴を抽出可能であると考えられる。また、入力データにノイズを加えることで、観測ノイズに対して頑強な特徴抽出が期待できる。

SCDAE は式 (4) の期待値最適化問題と共通した性質を持つが、エンコーダ f_{θ} およびデコーダ $g_{\theta'}$ が全結合のニューラルネットワークと異なる。SCDAE におけるエンコーダを $convf_{\theta}$ 、デコーダを $convg_{\theta'}$ とすると、 $k \in H$ 番目のフィルタ $convf_{\theta}(\tilde{x})^k$ は式 (5)、 $convg_{\theta'}(y)$ は式 (6) により定義される。ただし、 $*$ は畳み込み処理とする。

$$convf_{\theta}(\tilde{x})^k = \sigma(x * W^k + b^k) \quad (5)$$

$$convg_{\theta'}(y) = \sigma \left(\sum_{k \in H} convf_{\theta}(\tilde{x})^k * W'^k + b'^k \right) \quad (6)$$

SCDAE のエンコーダ層における畳み込み処理の前後にはプーリング層を挿入する。Pooling 層はエンコーダでは MaxPooling を行い、デコーダ層では、Upsampling を行う。MaxPooling は畳み込み層で計算されたフィルタの非

最大値以外を削除し、Upsampling では入力の値と同様の値を任意の回数繰り返す。

SCDAE の損失関数 L_{SCDAE} には二乗誤差 (MSE) を用いる。入力をノイズを加えた \tilde{x} 、出力を x としたとき、損失関数 L_{SCDAE} は式 (7) で定義される。

$$L_{SCDAE}(\theta) = \frac{1}{2n} \sum_{i=1}^n (x_i - \tilde{x}_i)^2 \quad (7)$$

3.2 分類器の構築 (fine-tuning)

SCDAE は分類機能を持たない。不整脈の検出を行うために、3.1 節で学習した SCDAE のエンコーダに全結合のニューラルネットワークを追加する。図 3 に分類器構築の概念図を示す。事前に学習した SCDAE の重みおよびエンコーダの構造を抽出し、出力に全結合層 (Fully connected layer) を追加する。全結合層の出力数を分類したい不整脈のラベルと揃えることで分類器を構築し、入力 \tilde{x} に対し、出力を与えられたラベルとして分類器を学習する。

分類器における出力層の活性化関数には、softmax 関数を用いる。softmax 関数を用いることで、各ユニットの出力を各ラベルへの所属確率として扱うことが可能となる。ここで、出力層におけるユニット数を N 、入力を x 、ユニット i の出力を x_i としたとき、ユニット i の出力 $p(i)$ は式 (8) で定義される。

$$p(i) = \frac{e^{x_i}}{\sum_{j=1}^N e^{x_j}} \quad (8)$$

分類器の損失関数 L_{CLF} には cross-entropy を用いる。サンプル数を n 、分類クラス数を m 、サンプル i におけるクラス j の分類器出力を p_{ij} としたとき、損失関数 L_{CLF} は式 (9) で定義される。

$$L_{CLF}(\theta) = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^m y_{ij} \log(p_{ij}) \quad (9)$$

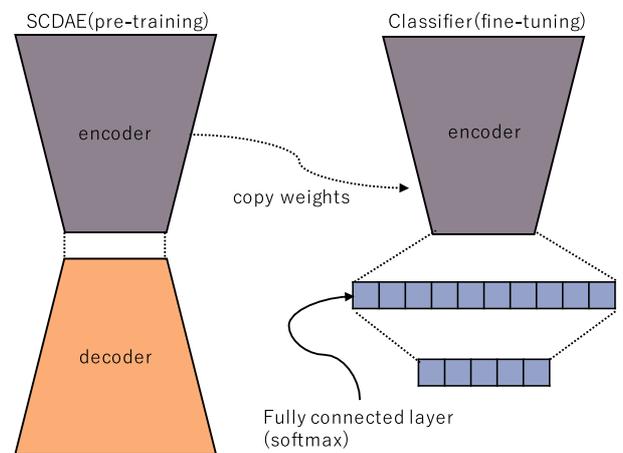


図 3 分類器の構築
Fig. 3 Building classifier.

表 1 不整脈の 5 分類

Table 1 Number of samples for each class.

Label	Description	Count	
		Train	Test
N	Normal beat	8,963	80,774
S	Supraventricular ectopic beat	336	4,457
V	Ventricular ectopic beat	993	9,201
F	Fusion beat	191	1,162
Q	Unknown beat	7	15

4. 実験

提案手法の有効性を確認するため評価実験を行った。ここでは実験の詳細と評価結果について説明する。評価は、以下の 2 つを行った。

評価 1 既存研究と同一条件による手法の性能比較評価

評価 2 未知ユーザに対する分類性能の評価

4.1 実験条件

実験データには、既存研究でひろく使われている 2 誘導 ECG データである MIT-BIH を用いた。MIT-BIH には 48 人の 30 分間における ECG データが存在する。各レコードには RRI およびラベルが存在し、ラベルは AAMI *3 の推奨する 5 分類に再分類可能となっている。表 1 に AAMI の推奨する不整脈の 5 分類と、ラベル数を示す。本研究では、先行研究と同様の条件で実験するため、MIT-BIH から 4 レコード (102, 104, 107, 217) を除外し、44 レコードに含まれる 100,389 の window を対象とする。

ECG 波形は window ごとに RRI の差異が存在する。また、観測対象者ごとに振幅に差異があるため、正規化をする。window ごとに RRI が統一されたデータを生成するため、フーリエ変換を用いデータを固定レートにリサンプリングする。次に、window ごとに異なる振幅を 0-1 間隔に正規化する。本実験では、各 window を 160 サンプルの固定レートにリサンプリングしたのち、正規化を行った。

評価 1 では、Zubair ら [8] の研究と同一の条件で評価を行う。具体的には、MIT-BIH のうち、最初の 20 人 (100-124) の全区間からラベル N, S, V をランダムに 75 サンプル、ラベル F, Q は全サンプル抽出した合計 245 サンプルと、全ユーザ (100-124 および 200-232 の 44 人) の最初 5 分間の全データをトレーニングデータとして利用する。24 人 (200-232) の後半 25 分のデータをテストデータとして用いる。また、テストデータのうちランダムにサンプリングした 5,000 件をバリデーションデータとして利用する。なお、バリデーションデータに利用したデータはテストデータから除いた。

評価 2 では、未知ユーザに対する分類性能を評価するた

表 2 SCDAE の構造

Table 2 Architecture of SCDAE.

	Layer	Type	Shape	Activation
	0	Noise	(160, 2)	
	1	Conv2D	(160, 16)	Relu
	2	MaxPooling	(80, 16)	
Encoder	3	Conv2D	(80, 8)	Relu
	4	MaxPooling	(40, 8)	
	5	Conv2D	(40, 4)	Relu
	6	MaxPooling	(20, 4)	
	7	UpSampling	(40, 4)	
	8	Conv2D	(40, 8)	Relu
	9	UpSampling	(80, 8)	
Decoder	10	Conv2D	(80, 16)	Relu
	11	UpSampling	(160, 16)	
	12	Conv2D	(160, 2)	Relu

め、100-124 および 200-232 の 44 人を 5 つのグループにランダムに分け、Leave-One-Group-Out Cross-Validation により評価を行った。グループが 5 つのため 5 分割交差検証 (各グループ 8 人または 9 人のデータを含む) を行った。すなわち、4 つのグループに含まれるデータで学習し、残りの 1 つのグループでテストを行うという評価を 5 回繰り返した。トレーニングに用いるグループのデータのうちランダムに 5,000 件をバリデーションデータとして利用した。なお、バリデーションデータに利用したデータはトレーニングデータから除いた。

4.2 実験結果

表 2 に 2 つの評価で利用した SCDAE の構造を示す。SCDAE では、3 層の畳み込み層およびプーリング層を利用した。また、活性化関数には Relu [20] を使い、最適化アルゴリズムには nadam [21] を利用した。また、破壊分布として平均 0、標準偏差 0.001 のガウス分布を用いた。

4.2.1 評価 1 の結果

本項では、既存研究と同一条件による性能比較の評価結果について述べる。図 4 に SCDAE の学習曲線を示す。テストデータにおける損失 (loss) およびバリデーションデータに対する loss (val-loss) が学習回数ごとに少なくなっていることが分かる。図 5 にテストデータの一部を SCDAE により復元した例を示す。復元されたデータが入力波形のノイズを取り除いているとともに、特徴については引き続き保持していることが分かる。

学習した SCDAE よりエンコーダ部分の構造および学習された重みを抽出し、全結合層を追加することで分類器を構築する。表 3 に構築された分類器の構造を示す。エンコーダ層に 32 次元および 5 次元の全結合層を追加した。また、損失関数には cross-entropy、最適化アルゴリズムには nadam を利用した。

図 6 に分類器の学習曲線、図 7 に学習回数ごとの Ac-

*3 <http://www.aami.org>

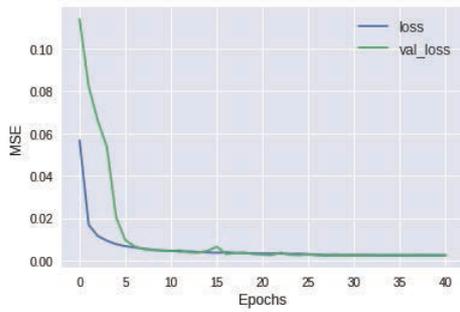


図 4 SCDAE の学習曲線
Fig. 4 Learning curve of SCDAE.

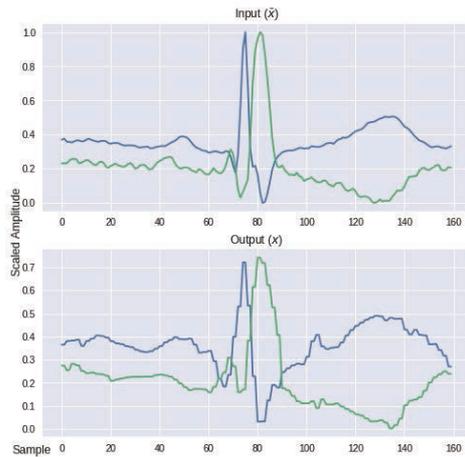


図 5 SCDAE の復元例
Fig. 5 Examples of recovered ECG by SCDAE.

表 3 分類器の構造

Table 3 Architecture of classifier.

	Layer	Type	Shape	Activation
Encoder	0	Noise	(160, 2)	
	1	Conv2D	(160, 16)	Relu
	2	MaxPooling	(80, 16)	
	3	Conv2D	(80, 8)	Relu
	4	MaxPooling	(40, 8)	
	5	Conv2D	(40, 4)	Relu
Classifier	6	MaxPooling	(20, 4)	
	7	Dense	80	Relu
	8	Dense	5	SoftMax

accuracy を示す。テストデータにおける損失 (loss) およびバリデーションデータに対する loss (val-loss) が学習回数ごとに少なくなっていることが分かる。Accuracy についても学習を重ねるごとに、トレーニングデータおよびテストデータにて増加していることから、分類器が高精度であるとともに汎化能力を持っていることが分かる。

学習した分類器でテストデータを分類した際の分類精度を表 4、分類結果を表 5 に示す。十分な観測データが存在するラベル N, V については precision/recall とともに高い精度で分類できていることが分かる。ラベル S, F について

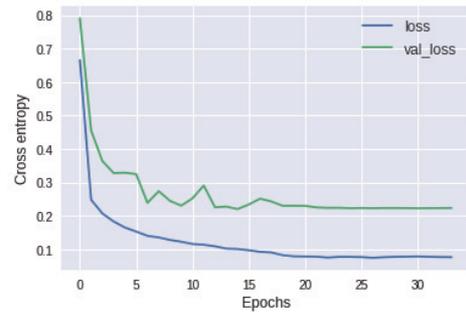


図 6 分類器の学習曲線
Fig. 6 Learning curve of classifier.

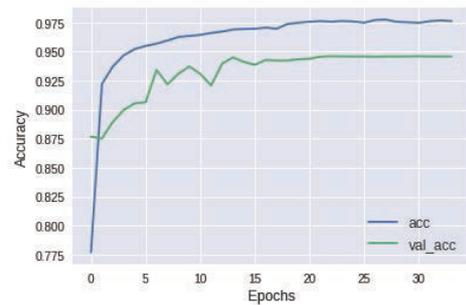


図 7 分類器の Accuracy
Fig. 7 Accuracy of classifier.

表 4 テストデータの分類精度

Table 4 Performance for test data.

Label	Precision	Recall	F1-score	Support
N	0.95	0.99	0.97	80,774
S	0.87	0.44	0.59	4,457
V	0.94	0.84	0.89	9,201
F	0.90	0.52	0.66	1,162
Q	0.00	0.00	0.00	15

表 5 テストデータの分類結果

Table 5 Results of classifier for each class.

Label	Classification result				
	N	S	V	F	Q
N	80,437	118	175	44	0
S	2,292	2,033	128	4	0
V	1,221	46	7,841	93	0
F	280	2	66	814	0
Q	13	0	2	0	0

は、precision が高い一方で、recall が低い。これは、表 1 に示したようにラベル S, F のトレーニングデータが少ないためであると考えられる。ラベル Q (Unknown beat) については分類ができていない。これは、ラベル Q のデータ数が極端に少ないため、分類器が十分な学習を行えないためであると考えられる。また、Unknown beat は波形にラベルをつけることが困難なデータであるため、ラベルリングが適切でない可能性がある。

提案手法と既存研究の Accuracy の比較を表 6 に示す。

表 6 既存研究との精度比較

Table 6 Comparison of accuracy between the proposed method and existing methods.

	Osowski '04 [6]	Srivastava '13 [4]	Tang '14 [5]	Zubair '16 [8]	Proposed (SC)	Proposed (SCDAE)
Acc	86%	85%	91.7%	92.7%	95.1%	95.3%

表 7 未知ユーザに対する分類の精度比較

Table 7 Accuracy for unseen data.

	Proposed (SC)	Proposed (SCDAE)
Accuracy	87.6%	91.7%

提案手法は CNN を積層 (stack) し多層にした要素 (Stacked CNN, 以下 SC モデル) と DAE を使って事前学習した要素が含まれる。そのため, SC モデルと, SC モデルに DAE を適用した SCDAE モデルの 2 種類の精度を既存研究と比較した。SC モデルも SCDAE モデルもどちらも分類精度 (Accuracy) が, 既存研究と比較し高いことが分かる。SC モデルと SCDAE モデルの差は 0.2% であった。このことから, 既存研究 [8] と同一の条件では CNN を積層にする効果の方が DAE の効果より大きいと考えられる。

4.2.2 評価 2 の結果

本項では, 未知ユーザに対する分類性能の評価結果について説明する。DAE は汎化性能の向上に寄与すると考えられるため [13], 未知ユーザに対する分類性能を SC モデルと SCDAE モデルで比較する。

表 7 に Leave-One-Group-Out Cross-Validation で 5 分割交差検証を行った結果を示す。SC モデルより SCDAE モデルの方が未知ユーザを高精度の分類を行うことができた。トレーニングデータにテストデータのユーザが含まれる評価 1 では SC モデルと SCDAE モデルで分類精度に大きな差はなかったが, 未知データのみを分類する評価 2 では DAE を加えたモデルの方が高精度に分類を行うことができた。この結果に対して, 対応のある t 検定を行ったところ, 有意水準 5% で有意な差があった。このことから, DAE を適用することが未観測データからの不整脈検出に有効であるといえる。

なお, 学習に要した時間は, 学習に用いたサンプル数の平均 80,551.2 サンプルで 697.11 秒であった。また, 推論に要した時間は, テストに用いたサンプル数の平均 15,137.8 サンプルで 0.856 秒であった。実行環境は, OS は Ubuntu 16.04, CPU は Intel Xeon CPU 3.20 GHz (16 コア), メモリ 128 GB, GPU に TITAN X (メモリ 12 GB) を利用した。

5. まとめ

本研究では, SCDAE を用いた ECG からの不整脈検出手法を提案した。ECG からの不整脈検出で問題となる観測対象および心拍変動による波形変化については, CAE に

よる高レベルかつ位置普遍性を持つ特徴抽出に着目し, 観測ノイズについては DAE によるノイズ除去に着目することで, SCDAE による特徴抽出が有効であることを示した。また, 事前学習した SCDAE の構造および重みを利用した分類器を構築し再学習することで, 既存研究と比較し未知の波形分類が高精度で行えることを示した。

今後の課題として 2 誘導 ECG だけではなく, 臨床分野で活用されている 12 誘導 ECG について SCDAE を適用することがあげられる。12 誘導 ECG は, 2 誘導 ECG と比較し多量かつ空間的な心電情報を観測することが可能である一方, 情報が多量であるため目視での検査には限界がある。そのため提案手法を適用することで, 効率的に不整脈の分類が可能となることが期待できる。また, 本論文では DAE のノイズとして平均 0, 標準偏差 0.001 のガウス分布を利用したが, 他の関数やパラメータを利用することによって分類性能を向上できる可能性があるため, それらの評価も今後の課題である。

参考文献

- [1] Gubbi, J., Buyya, R., Marusic, S. and Palaniswami, M.: Internet of Things (IoT): A vision, architectural elements, and future directions, *Future Generation Computer Systems*, Vol.29, No.7, pp.1645–1660 (2013).
- [2] 高河原和彦, 小野一善: 心拍計測ウェアの技術と応用例, *電気学会誌*, Vol.136, No.3, pp.139–142 (2016).
- [3] Zhao, C., Zhao, M., Liu, J. and Zheng, C.: Electroencephalogram and electrocardiograph assessment of mental fatigue in a driving simulator, *Accident Analysis & Prevention*, Vol.45, pp.83–90 (2012).
- [4] Srivastava, V. and Prasad, D.: Dwt-Based Feature Extraction from ecg Signal, *American J. Eng. Research (AJER)*, Vol.2, No.3, pp.44–50 (2013).
- [5] Tang, X. and Shu, L.: Classification of electrocardiogram signals with RS and quantum neural networks, *International Journal of Multimedia and Ubiquitous Engineering*, Vol.9, No.2, pp.363–372 (2014).
- [6] Osowski, S., Hoai, L.T. and Markiewicz, T.: Support vector machine-based expert system for reliable heart-beat recognition, *IEEE Trans. Biomedical Engineering*, Vol.51, No.4, pp.582–589 (2004).
- [7] Kiranyaz, S., Ince, T. and Gabbouj, M.: Real-time patient-specific ECG classification by 1-D convolutional neural networks, *IEEE Trans. Biomedical Engineering*, Vol.63, No.3, pp.664–675 (2016).
- [8] Zubair, M., Kim, J. and Yoon, C.: An Automated ECG Beat Classification System Using Convolutional Neural Networks, *2016 6th International Conference on IT Convergence and Security (ICITCS)*, pp.1–5, IEEE (2016).
- [9] Al Rahhal, M., Bazi, Y., AlHichri, H., Alajlan, N., Melgani, F. and Yager, R.: Deep learning approach for active classification of electrocardiogram signals, *Information Sciences*, Vol.345, pp.340–354 (2016).
- [10] Rajpurkar, P., Hannun, A.Y., Haghpanahi, M., Bourn, C. and Ng, A.Y.: Cardiologist-level arrhythmia detection with convolutional neural networks, arXiv preprint arXiv:1707.01836 (2017).
- [11] Pourbabae, B., Roshtkhari, M.J. and Khorasani, K.:

Deep Convolutional Neural Networks and Learning ECG Features for Screening Paroxysmal Atrial Fibrillation Patients, *IEEE Trans. Systems, Man, and Cybernetics: Systems* (2017).

- [12] Hinton, G.E. and Salakhutdinov, R.R.: Reducing the dimensionality of data with neural networks, *Science*, Vol.313, No.5786, pp.504–507 (2006).
- [13] Vincent, P., Larochelle, H., Bengio, Y. and Manzagol, P.-A.: Extracting and composing robust features with denoising autoencoders, *Proc. 25th International Conference on Machine Learning*, pp.1096–1103, ACM (2008).
- [14] Krizhevsky, A., Sutskever, I. and Hinton, G.E.: ImageNet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems*, pp.1097–1105 (2012).
- [15] Kim, Y.: Convolutional neural networks for sentence classification, arXiv preprint arXiv:1408.5882 (2014).
- [16] Zhang, X., Zhao, J. and LeCun, Y.: Character-level convolutional networks for text classification, *Advances in Neural Information Processing Systems*, pp.649–657 (2015).
- [17] Scherer, D., Müller, A. and Behnke, S.: Evaluation of pooling operations in convolutional architectures for object recognition, *Artificial Neural Networks–ICANN 2010*, pp.92–101 (2010).
- [18] Masci, J., Meier, U., Cireşan, D. and Schmidhuber, J.: Stacked convolutional auto-encoders for hierarchical feature extraction, *Artificial Neural Networks and Machine Learning–ICANN 2011*, pp.52–59 (2011).
- [19] Du, B., Xiong, W., Wu, J., Zhang, L., Zhang, L. and Tao, D.: Stacked Convolutional Denoising Auto-Encoders for Feature Representation, *IEEE Trans. Cybernetics*, Vol.47, No.4, pp.1017–1027 (2017).
- [20] Glorot, X., Bordes, A. and Bengio, Y.: Deep Sparse Rectifier Neural Networks, *Aistats*, Vol.15, No.106, p.275 (2011).
- [21] Dozat, T.: Incorporating Nesterov momentum into Adam, Technical report, Stanford University, Technical Report (2015) (online), available from (<http://cs229.stanford.edu/proj2015/054report.pdf>).

推薦文

本研究は2誘導心電図から不整脈を発見するための手法について提案している。心拍特徴の観測対象の違い、心拍特徴の動的な変化、観測ノイズ、といった実用上不可避な問題に対して、それらに頑健な特徴抽出を実現し、さらに未知の心拍波形について高精度な分類能力を持った分類器を実現している。この研究のアプローチは他のセンサ信号処理でも参考にしうる点が多いことから、情報処理学会論文誌へ推薦する。

(モバイルコンピューティングとパーベイシブシステム
研究会主査 河口信夫)



高橋 柁 (正会員)

2015年北陸先端科学技術大学院大学知識科学研究科修士課程修了。同年株式会社NTTドコモ入社。2018年SAS Institute Japan株式会社入社。現在に至る。機械学習、自然言語処理に関する研究開発に従事。



落合 桂一 (正会員)

2006年千葉大学工学部情報画像工学科卒業。2008年同大学大学院博士前期課程修了。同年株式会社NTTドコモ入社。2017年東京大学大学院工学系研究科博士後期課程修了。位置情報関連SNS、行動ログおよびヘルスケアデータ解析の研究開発に従事。ACM, 日本データベース学会, 人工知能学会各会員。博士(工学)。



深澤 佑介 (正会員)

2002年東京大学工学部卒業。2004年東京大学大学院工学系研究科修士課程修了。同年株式会社NTTドコモ入社。2011年東京大学大学院工学系研究科博士後期課程修了。同年10月東京大学人工物工学研究センターで協力研究員、2017年より客員研究員兼任。現在に至る。Webマイニング、レコメンデーション、実世界行動予測に関する研究開発を行っている。IEEE, 人工知能学会各会員。博士(工学)。