

# 深層学習による個人に特化した正常波形を基にする 心電図異常判定

堀将太<sup>1</sup> 生野冬流<sup>1</sup> 行天啓二<sup>1</sup> 大城英裕<sup>1</sup> 高見利也<sup>1</sup> 佐藤昇<sup>2</sup>

**概要**：近年、地方の医師不足が深刻化しており、医療分野において自動診断の研究が盛んになっている。心電図は個人ごとに異なるパターンを有しており、個人に合わせた心電図の異常判定を行うことが望ましい。本研究では、深層学習の一種である Autoencoder と CNN を用いた、個人に特化した心電図異常判定手法を提案する。本手法は、個人の心電図データとして十分な量を収集することができる正常波形のみを Autoencoder を用いて学習することにより、個人固有の正常波形の特徴を獲得する。また、判定対象となる心電図データから獲得される特徴の軌跡と、正常波形の特徴の軌跡を図示して比較することにより、正常か異常かの判定根拠を示すことが可能なシステムの構築を目指す。心電図のデータベースである MIT-BIH のデータを用いた実験により、Autoencoder による特徴獲得について改善の余地が残されているものの、提案手法は、所与の目的を満足しうる可能性を持つことを示すことができた。

**キーワード**：心電図解析、深層学習、Autoencoder、MIT-BIH 不整脈データベース

## Judgement of ECG abnormalities based on individual-specific normal waveforms using deep learning

SHOTA HORI<sup>†1</sup> TORU SHONO<sup>†1</sup> KEIJI GYOHTEN<sup>†1</sup>  
HIDEHIRO OHKI<sup>†1</sup> TOSHIYA TAKAMI<sup>†1</sup> NOBORU SATO<sup>†2</sup>

**Abstract** : In the medical field, researches on automatic diagnosis are being actively conducted against the backdrop of the shortage of local doctors. Since the ECG has different patterns for each individual, it is desirable to judge the ECG abnormalities according to each patient. In this study, we propose an individualized ECG abnormality judgment method using Autoencoder and CNN. This method makes Autoencoder learn only normal waveforms that can be easily collected enough and obtains the characteristics of the individual's unique normal waveforms. In addition, we aim to construct a system that can show the reason for judging an abnormality by comparing the trajectory of the feature obtained from the target ECG data with the one of the normal waveform. Although there is room for improvement in the feature acquisition by Autoencoder, experiments using MIT-BIH data shown that the proposed method has the potential to satisfy the given purpose.

**Keywords**: ECG analysis, deep learning, Autoencoder, MIT-BIH arrhythmia database

### 1. はじめに

近年、地方では医師不足が深刻化している。医師でなければ診断が困難な病気が多々存在することもあり、診療までの待ち時間が増加してしまうことなどの問題が懸念されている。このような背景から、医療分野において自動診断へのニーズが高まっている。現在、医療分野では日常業務でさまざまなツールが使われているが、本研究では、その中でも広く用いられる心電図に着目した。心電図の自動解析は周波数解析に基づく手法が多く、フーリエ分析やウェーブレット分析に基づくもの[1]が広く知られている。近年では、深層学習の発展を受け、深層学習を用いて自動的に心電図の異常検知をする研究[2]も、他の医療分野のツールを用いた自動診断の研究[3]と同様に盛んである。深層学習による心電図の自動診断においては、教師あり学習に基づく手法が主流である。これらは、正常な心電図波形(正常波

形)か異常な心電図波形(異常波形)か、また、異常波形の場合は、異常波形の種類をラベル付けした心電図データを学習することで異常判定する手法である。しかし、これらの手法には大きく2つの欠点が存在する。1つ目は、汎用的な判定になる点である。従来では、複数人の心電図を解析することで心電図の自動分類が行われており、汎用的な診断になってしまうことから、解析の精度に限界があるとされている[4]。本来、心電図は個人ごとに異なる波形パターンを保有するため、個人ごとに特化した心電図の自動診断をすることが望ましい。しかし、個人ごとに異常ラベルを用意することは難しく、大変手間がかかるため、個人ごとに特化した判定は困難であり、あらゆるユーザーを対象とした汎用的な手法にならざるを得ない。2つ目は、自動診断の判定根拠を得ることが困難なことである。従来の深層学習による心電図自動診断では、判定する過程がブラックボックスであるため、判定の根拠を得ることが難しい。心

<sup>1</sup> 大分大学  
Oita University  
<sup>2</sup> 社会医療法人 敬和会  
Keiwakai Healthcare Group

電図自動診断に限らず、深層学習を用いた様々なパターン認識手法では、何故そのような認識をしたのかという根拠を示すことが困難であるという問題が指摘されている[5].

本研究では、上記で挙げた問題点を解決するために、Autoencoder と CNN を用いて、心電図の正常波形のみで学習を行い、正常波形の本質的な特徴を2次元の特徴空間に連続的に写像する。入力データの特徴の軌跡が、学習した正常波形の軌跡と同じような軌跡を辿るか比較することで、心電図の異常判定を行う手法を提案する。1つ目の問題に対しては、心電図データにラベル付けをする必要がないAutoencoder を適用することで、個人に特化した心電図異常判定システムを構築することにより、解決を図る。2つ目の問題に対しては、特徴の軌跡を図示することで、正常であるか、異常であるかの判定の根拠を示すことにより、解決を図る。また、従来の心電図自動解析は「1秒」や「1拍」といった短時間のデータにおける異常波形の判定を行っている。しかし、心電図は経時的な変化を見なければ診断が困難である場合が存在し、長時間での変動を観察する必要がある[1]。この問題に対しては、長期的な心電図のデータを扱うことで解決を図る。本研究の最終的な目的は長期的な異常を考慮し、個人に特化した心電図自動診断システムを構築することである。

本論文では、まず2章で関連研究を述べ、3章で提案するシステムについて述べる。4章で実験とその結果を述べ、5章にまとめと今後の課題を述べる。

## 2. 関連研究

過去にも、深層学習を用いた個人ごとの心電図を扱った心電図自動解析の研究、また、長期的な心電図の特徴を可視化し判定の根拠を示す研究が行われている。以下に、代表的な手法を取り上げ、その概要について述べる。

### 2.1 Convolutional Neural Network for Patient Specific ECG Classification [6]

Kiranyaz らは、1次元 CNN を用いて、高速で正確な患者固有の心電図分類と、患者の心電図の状態を監視するシステムを提案している。心電図波形の入力データを比較的小さくすることで、正確で高速に学習することができる。また、学習データとして、各患者共通の心電図データと個人ごとのデータを用いることで、個人に合わせた異常検知をしている。ラベルは、正常波形1種類と異常波形4種類である。この手法では、実際にシステムを利用する際、心電図のラベルデータを患者ごとに用意しなければならない、異常のラベルデータを用意することは困難であるとされている。また、判定する過程がブラックボックスであるため、判定の根拠の分析ができない。そのため、異常のデータの用意がいらず、判定の根拠の分析が可能な手法が望ましいと考えられる。

### 2.2 深層学習を用いた心電図波形の長期変動パターン抽出法 [7]

尾亦らは、Autoencoder と主成分分析により、心電図波形を学習し、特徴を可視化するシステムを提案している。この手法では、心電図の長時間の波形を固定長に切り出し、それぞれを Autoencoder によって低次元化する。さらに、低次元化された波形を主成分分析により2次元の特徴空間に連続的に写像し、心電図波形の長時間の変化を軌跡として可視化する。これにより、既存手法とは異なり、入力データの時系列性を保持して扱うことができ、長時間での変動に基づく心電図の分析が可能となる。実験では、心電図波形を4つのクラスに定性的に分類することができることが分かった。さらに、未知のテストデータに対して提案手法を適用したところ、特異な疾病を持つ患者を、可視化結果の定性的な特異性から発見している。この結果から、特徴空間への写像結果と疾病とのつながりについて、何らかの規則性や関連性を見い出せる可能性が示唆された。しかしながら、定量的な評価はできておらず、また、得られた軌跡に対して明確に意味をもたせることも、現地点では困難であるとされている。今後、解釈性を高めなければならないと考えられる。

## 3. 提案手法

本文では、従来手法の問題点を解決する提案手法について説明する。3.1 では提案手法の概要について述べ、3.2, 3.3, 3.4 では手順ごとに詳細な説明をする。

### 3.1 概要

提案手法では、個人ごとに正常波形のみの心電図データを Autoencoder により学習し、個人の心電図の本質的な特徴を獲得する。獲得された正常波形の特徴を基に、入力された波形が正常波形か異常波形であるかを判定する。Autoencoder を用いて個人ごとに正常波形の特徴を獲得する理由は3つある。

1つ目は、ノイズに対して頑強にするためである。ノイズは測定に用いる心電計などにより発生し、誤診を招くおそれがある。このことから、心電図のノイズ除去を目的とした手法は多く提案されており、心電図自動解析をノイズに対し頑強にすることは重要であると考えられる。Autoencoder はデータの本質的な特徴を獲得するため、ノイズに対し頑強になることが期待できる。

2つ目は、特徴の可視化が可能な点である。特徴空間上の正常波形の本質的な特徴と、異常波形の本質的な特徴を図示しながら照らし合わせることで、心電図自動診断の根拠とすることが期待できるためである。

3つ目は、Autoencoder は学習において、異常な心電図を準備する必要がなく、容易に収集することができる正常な心電図のみを学習できる点である。医師が正常と判断した心電図のみを学習させることが可能であり、医師が過去に

使用者の正常であると診断した心電図があれば、個人ごとに異常のデータを用意する必要がない。そのため、実環境においても実現が容易である。

図 1 に示すように、提案手法では以下の手順を踏む。

- (1) Autoencoder で個人ごとの正常波形のみを学習し、エンコード部で次元削減することで正常波形の本質的な特徴を 2 次元の特徴ベクトルとして獲得
- (2) (1)で獲得した特徴ベクトルを特徴空間に写像することで、使用者の正常波形の特徴の軌跡を獲得
- (3) (2)で獲得した正常波形の特徴の軌跡と、入力する心電図の特徴の軌跡を比較して、乖離していれば異常波形を含むと判定し、類似していれば正常な波形と判定

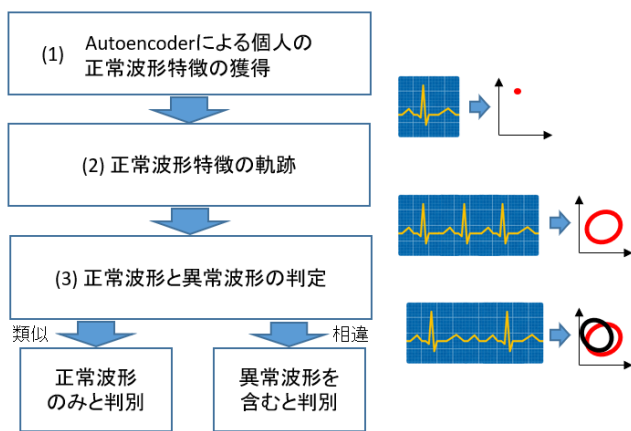


図 1 提案手法の流れ

Figure 1 Flow of the proposed method.

### 3.2 Autoencoder による個人の正常波形特徴の獲得

Autoencoder により、正常波形を 2 次元にまで次元削減し、正常波形のみの心電図データから特徴を獲得する。表 1 は、本手法の CNN ベースの Autoencoder のネットワーク構造である。ネットワーク構造は 6 層の convolution 層、deconvolution 層と 3 層の pooling 層、unpooling 層から構成されている。入力データと出力データは 1 次元の波形データ  $1 \times 500$  であり、エンコード部の後で 2 次元データに Autoencoder のエンコード部を全結合する。

### 3.3 正常波形特徴の軌跡獲得

3.2 で得られた 2 次元データを、特徴空間に連続的に写像する。図 2 は、従来手法で多く見られる、1 つの波形を切り取って入力データとして与える方法を示している。各波形は、R 波のピークを中心として幅をとって切り取られる。切り取ったデータに対し、正常か異常か、あるいは異常の種類をラベルとして与えることが多い。

図 3 は、提案手法の入力データの与え方である。提案手法では、R 波のピークを考慮せず、一定の時間間隔でずらしつつ、一定の幅で心電図データを切り取っていく。この

ように逐次的に与えられる入力データを学習し、Autoencoder の中間層の Full-1 から獲得した正常波形の特徴を並べることで、規則的な軌跡を得ることが可能となる。

提案手法では、ラベルを付与しない代わりに、あらかじめ正常波形と診断された波形データのみを、学習データとして用いる。

表 1 実験に用いた Autoencoder の構造

Table 1 Autoencoder structure used in the experiment.

Name	Shape	Operation performed
Input	$1 \times 500$	-----
Conv-1	$16 \times 1 \times 485$	$1 \times 16$ convolution
Conv-2	$16 \times 1 \times 478$	$1 \times 8$ convolution
Pool-1	$16 \times 1 \times 59$	$1 \times 8$ maxpool
Conv-3	$16 \times 1 \times 52$	$1 \times 8$ convolution
Conv-4	$16 \times 1 \times 49$	$1 \times 4$ convolution
Pool-2	$16 \times 1 \times 24$	$1 \times 2$ maxpool
Conv-5	$16 \times 1 \times 23$	$1 \times 2$ convolution
Conv-6	$16 \times 1 \times 23$	$1 \times 1$ convolution
Pool-3	$16 \times 1 \times 11$	$1 \times 2$ maxpool
Full-1	2	-----
Deconv-1	$16 \times 1 \times 2$	$1 \times 1$ deconvolution
Deconv-2	$16 \times 1 \times 3$	$1 \times 2$ deconvolution
Unpool-1	$16 \times 1 \times 6$	$1 \times 2$ unpool
Deconv-3	$16 \times 1 \times 9$	$1 \times 4$ deconvolution
Deconv-4	$16 \times 1 \times 16$	$1 \times 8$ deconvolution
Unpool-2	$16 \times 1 \times 32$	$1 \times 2$ unpool
Deconv-5	$16 \times 1 \times 39$	$1 \times 8$ deconvolution
Deconv-6	$16 \times 1 \times 54$	$1 \times 16$ deconvolution
Unpool-3	$16 \times 1 \times 432$	$1 \times 8$ unpool
Output(Full-2)	$1 \times 500$	-----




図 2 従来手法の入力データの与え方

Figure 2 How to provide input data in the conventional method.




図 3 提案手法の入力データの与え方

Figure 3 How to provide input data for the proposed method.

### 3.4 正常波形と異常波形の判定

学習で Autoencoder により獲得した正常波形の特徴の軌跡と、実際に判定を行うテストデータの特徴の軌跡を比較することで、テストデータに異常波形が含まれているか判定する。本手法では、連続した 150 個の 2 次元の特徴ベクトルを 1 つのセットとし、その部分の波形データが異常波形を含むかを判定する。判定方法として 2 つの手順を踏む。

- (3-1) 入力データの 1 つの点と、学習で得た正常波形の軌跡のうち最も近い点とのユークリッド距離を求め、しきい値以上であれば異常の可能性のある入力データとする(これ以降、このしきい値を、しきい値  $a$  と呼ぶ)。
- (3-2) 150 個の点のうち、異常の可能性があると判定された入力データの割合を異常波形を含む確率として求め、しきい値以上であれば、異常な波形が含まれていると判定する(これ以降、このしきい値を、しきい値  $b$  と呼ぶ)。

以下に、各手順およびしきい値の定め方を説明する。

(3-1)で使用するしきい値  $a$  は、学習の検証データを用いて算出する。判定時と同様に、検証データを用いて学習で得た正常波形の軌跡のうち、最も近い点とのユークリッド距離を求める。このユークリッド距離の値が大きいものをしきい値とする。本手法では、しきい値が外れ値を定めないようにするため、最も離れた点ではなく、距離の大きさが上位 10%の部分をしきい値とする。例えば、しきい値を求めるためのデータを 100 個与えた場合は 11 番目に大きいユークリッド距離をしきい値と定める。図 4 では青の点が学習した正常波形の特徴を示し、オレンジが入力データの特徴、赤線がユークリッド距離を示す。しきい値よりも赤線の長さが長い点を異常の可能性のある点、短い点を正常である点とする。




図 4 判定方法

Figure 4 Judgment method.

(3-2)では、1 セットとした 150 個の点のうち、手順(3-1)で異常の可能性があると判定された点の数により、異常波形を含む割合を計算する。例えば、手順(3-1)で異常と判定された点が 75 個の場合、150 個のうち、75 個が異常の可能性のあるため、1 セットが異常である割合は 50%とする。異常波形を含む割合がしきい値以上であれば 1 セット内に異常波形を含む、しきい値未満であれば異常波形を含まないと判定する。しきい値は、数名のデータをサンプルにして事前に算出するものとし、最も精度の高いしきい値を求め本手法に適用する。

## 4. 実験

本章では提案手法の有効性を示すために行った 2 つの実験の概要と結果、考察を述べる。

実験 1 では、提案手法で獲得した 2 次元の特徴ベクトルの写像結果を表示し、正常波形の軌跡と異常波形の軌跡の比較を行う。また、正常波形のみのデータと異常波形を含むデータのユークリッド距離を求めてグラフにし、異常であるかの判定の根拠を示すことが可能であるか、定性的に評価をする。

実験 2 では、提案手法による心電図異常判定の精度を定量的に評価し、提案手法の有効性を確認する。また、Autoencoder を用いて入力波形の特徴を獲得することの有効性の確認のため、提案手法において Autoencoder を用いた場合と、用いずに入力波形をそのまま特徴として用いた場合との判定精度を比較する。

### 4.1 データセット概要

本研究では MIT-BIH 不整脈データベース[8]から取得した 11 人の心電図波形を使用した。このデータセットではホルター心電図記録装置で記録された 48 人の 30 分の心電図波形が記録されている。心電図の異常のクラスは、Association for the Advancement of Medical Instrumentation (AAMI)が推奨する基準により表 2 の 5 つに分類される。N は正常波形で、それ以外は異常波形である。SVEB は上室性心拍、VEB は心室性心拍、F は融合収縮に分類され、Q はどのクラスにも分類されない異常波形を示す。このラベルは R 波ごとについている。

表 2 心電図の異常クラス  
 Table 2 Abnormal ECG class.

AAMI Heartbeat Classes	N	SVEB	VEB	F	Q
------------------------	---	------	-----	---	---

サンプリング周波数は 360Hz である。学習において、波形の入力のサイズは  $1 \times 500$  としている。訓練データは 29000 個であり、検証データは 1000 個である。訓練データ、検証データともに異常波形を含まない正常波形の心電図波形を用いる。また、バッチサイズは 128 である。テストデータは正常波形と異常波形で構成されており、個人によって異常波形の数が異なるため、テストデータの数も個人ごとに異なる。なお、テストデータにおける正常波形の数は 11 人とも 3000 個としている。

本実験では異常判定をする際に、正常と異常を判定するしきい値を必要とする。その為、11 人のうち 6 人は、しきい値を決めるための訓練データとする。各個人の異常波形を含むテストデータの数を表 3 と表 4 に示す。表 3 は異常判定をする際に用いるしきい値を定めるための学習データとした 6 人の異常波形の数および、テストデータの数である。表 4 は実際に実験で用いる 5 人の異常波形の数および、テストデータの数である。テストデータは 1 つの異常に対して 150 個のデータを用意する。なお、異常を中心として 150 個のテストデータをスライド窓方式で用意する。

E, I, K の人については厳密に言えば訓練データに正常波形ではなく、それぞれ L, R, R と判定された心電図データのラベルが付いている。

表 3 しきい値を定めるための 6 名の異常波形

Table 3 6 abnormal waveforms to determine the threshold.

テストID	SVEB	VEB	F	Q	テストデータ数
A	33	1	0	0	$34 \times 150$
B	3	0	0	2	$5 \times 150$
C	2	0	0	0	$5 \times 150$
D	0	41	0	5	$46 \times 150$
E	0	38	2	0	$40 \times 150$
F	6	0	0	0	$6 \times 150$

表 4 実際にテストで用いる 5 人の異常波形

Table 4 Abnormal waveform of 5 people actually used in the test.

テストID	SVEB	VEB	F	Q	テストデータ数
G	12	43	4	0	$59 \times 150$
H	1	109	0	0	$110 \times 150$
I	95	16	0	0	$111 \times 150$
J	0	3	0	0	$3 \times 150$
K	31	47	5	0	$83 \times 150$

## 4.2 実験 1

実験 1 では、11 人の心電図データから提案手法で獲得した 2 次元の特徴ベクトルの写像結果を、学習に使用した正

常波形の訓練データ、正常波形のテストデータ、異常波形を含むテストデータの 3 つに分けて表示した。また、学習した正常波形から得られた軌跡と入力されたテストデータ 1 つの点とのユークリッド距離を求め、棒グラフとして表示し、比較を行った。

11 名のうち、3 名を例に挙げ、写像結果を示す。図 5 は D、図 6 は F、図 7 は J の写像結果を示す。上図の赤い軌跡が訓練データの結果、中央の青い軌跡が正常波形のテストデータの結果、下図の黒い軌跡が異常波形を含むテストデータの結果である。




図 5 D の写像の結果

Figure 5 Result of mapping D.




図 6 F の写像の結果

Figure 6 Result of mapping F.






図 7 J の写像の結果  
Figure 7 Result of mapping J.

次に、3 人のユークリッド距離を棒グラフにして示す。距離が大きいほど学習データの軌跡から離れており、異常である可能性を示す。図 8, 9, 10 に D, F, J の結果を示す。X 軸方向の 0 から 1000 までが学習の際の検証データ、1000 から 4000 が正常波形のテストデータ、4000 から最後までが異常波形を含むテストデータである。




図 8 D のユークリッド距離  
Figure 8 D Euclidean distance.

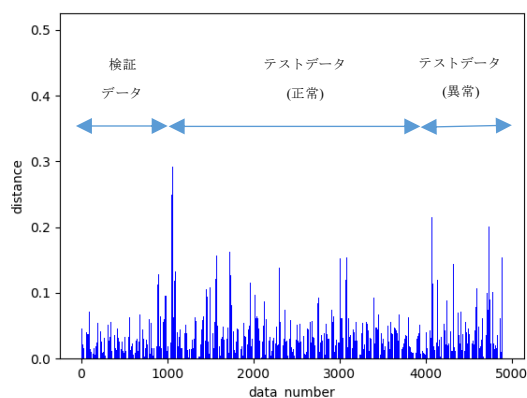


図 9 F のユークリッド距離  
Figure 9 F Euclidean distance.




図 10 J のユークリッド距離  
Figure 10 J Euclidean distance.

D の人の結果から、正常波形のテストデータは学習データと類似した軌跡を描き、異常波形は訓練データとは異なる軌跡を描いた。このことから、提案手法は判定の根拠を得ることができる可能性を示した。また、異常波形を含むテストデータのユークリッド距離は、正常波形のみのデータに比べ、全体的に大きくなっていることがわかる。提案手法により、判定の根拠を示すことができ、定性的にも異常波形を判定できることが確認できた。

しかし、F や J の人のように、異常波形の有無にかかわらず学習データの軌跡とテストデータの軌跡が類似する場合が確認された。原因の一つとして、Autoencoder により、心電図波形の特徴がうまく獲得できておらず、ネットワーク構成が完全ではないことが挙げられる。F と J において特徴がうまく獲得できていない点は、Autoencoder による訓練データの復元結果が、入力と大きく異なっていることから確認される。これは、F と J 以外にも見られた。また、Autoencoder で 2 次元まで削減したことで本来削減すべきでない必要な情報まで削減してしまっていることも要因として考えられる。このことから、獲得する特徴を 2 次元より大きくする必要があると考える。

#### 4.3 実験 2

実験 2 では、実験 1 で求めたユークリッド距離を用いることで、提案手法の判定の精度を算出し、定量的に評価をする。評価の際、2 値分類でしばしば用いられる AUC を用いる。実際の認識率の比較として、次元削減していない波形データに最近傍法を用いて、学習した正常波形とテストの波形とのユークリッド距離を算出した手法と、提案手法の比較を行う。本節では、AUC の説明、判定精度の算出方法、判定におけるしきい値の算出方法について述べ、最後に結果と考察を述べる。

AUC とは、2 値分類でしばしば用いられる評価指標であり、TPR(真陽性率)と FPR(偽陽性率)という 2 つの数値から、

図 11 のような曲線を求めることで得られる数値である。各点は、異常波形か正常波形か判定するしきい値を変えることで変動する。この曲線を ROC 曲線といい、面積が AUC である。AUC の最大値は 1 であり、1 に近づくほど精度が高い。表 5 は 2 値分類した際に割り出される 4 つの数値を表に示したものである。表 5 の数値から TPR, FPR を求めることができる。式(1), 式(2)は本実験における TPR と FPR の求め方である。

$$TPR=TP/(TP+FN) \quad (1)$$

$$FPR=FP/(FP+TN) \quad (2)$$




図 11 ROC 曲線と AUC  
Figure 11 D Euclidean distance.

表 5 2 値分類で割り出される 4 つの数値

Table 5 Four numerical values determined by binary classification.

		判定結果	
		異常波形	正常波形
実際の波形	異常波形	TP(True Positive)	FN(False Negative)
	正常波形	FP(False Positive)	TN(True Negative)

本実験では、2 値分類の精度指標で用いられる数値である F 値と判定精度 Accuracy を用い、Autoencoder を適用した場合としない場合を比較している。F 値は適合率 Precision と再現率 recall から算出する。各数値は表 5 の数値を使い、以下の式で求める。

$$Precision=TP/(TP+FP) \quad (3)$$

$$recall=TPR=TP/(TP+FN) \quad (4)$$

$$F=(2 \times recall \times Precision)/(recall+Precision) \quad (5)$$

$$Accuracy=(TP+TN)/(TP+FP+TN+FN) \quad (6)$$

提案手法では、心電図の異常判定をするにあたって、定めるしきい値 a としきい値 b が存在する。

しきい値 a は、入力したテスト波形のユークリッド距離に基づき、その距離が異常の可能性があるとみなすかの判別するためのしきい値である。このしきい値は学習の検証データ 1000 個から算出する。今回この検証データ 1000 個のユークリッド距離を算出し、101 番目に大きい距離をしきい値とした。101 番目の距離をしきい値とした理由は、心電計による外れ値を考慮したためである。

しきい値 b は、1 つ目のしきい値を基に、連続した入力波形に対してある区間での異常波形の可能性、つまり、ある区間においての異常と判断するための値をしきい値とする。今回はしきい値の算出のため、しきい値を定めるための 6 名の学習データで実験を行い、ROC 曲線を出し、TPR が 1 に近いかつ、FPR が最小の点の時の値をしきい値とする。

表 6 は提案手法において Autoencoder を用いた場合と、用いずに入力波形をそのまま最近傍法により 2 次元の特徴として用いた場合の AUC を示す。

表 6 AUC

Table 6 AUC.

提案手法	比較手法
0.937	0.893

次に F 値と Accuracy を表 7, 8 に示す。

表 7 F 値

Table7 F value.

	提案手法	比較手法
G	0.773	0.338
H	0.820	0.952
I	0.712	0.977
J	0.833	1.000
K	0.714	0.755
平均	0.770	0.804

表 8 Accuracy  
Table 8 Accuracy.

	提案手法	比較手法
G	0.806	0.602
H	0.786	0.950
I	0.676	0.977
J	0.800	1.000
K	0.600	0.675
平均	0.734	0.841

表 6 の結果から、提案手法の方が AUC が高い結果を示した。しかし、表 7, 8 から G の人は提案手法の方が有効であったものの、他 4 名は比較手法の方が精度が高い結果になった。この原因としても、実験 1 の考察にもある通り、心電図波形の特徴を完全に獲得できていないことが考えられる。

## 5. まとめ

本稿では、心電図自動解析の従来課題であった、自動分類の判定が汎用的である点、解析結果がブラックボックスである点、経時的な変化による異常を考慮しなければならない点に着目し、深層学習の一種である Autoencoder と CNN を用いて、個人に特化した正常波形を基にする心電図異常判定を提案した。実験の結果から、提案手法において判定の根拠の分析が可能であること、また、いくつかの課題を解決することで、さらに精度を向上できる可能性があることを確認した。

今後の課題として、大きく 2 つが挙げられる。1 つ目は、ネットワークの再検討である。Autoencoder による次元削減により、心電図データの必要な情報まで削減されている可能性があるため、獲得する特徴を 3 次元以上の多次元にすることを検討する必要がある。2 つ目は、しきい値の定め方を再検討することである。今回の判定方法が医学的に有効であるかの確認、定量的な評価方法の再検討などが必要である。

## 参考文献

- [1] P.S.Addison : Wavelet transforms and the ECG : a review. *Physiol Meas.* vol.26, No.5, 2005, p.155-199.
- [2] M.Kachuee et al. : ECG Heartbeat Classification: A Deep Transferable Representation, 2018 IEEE International Conference on Healthcare Informatics (ICHI), 2018, pp.443-444.
- [3] G.Litjens et al. : A survey on deep learning in medical image analysis, *Medical Image Analysis* vol.42, 2017, p.60-88.
- [4] 平岡 昌和 : 心電図自動診断の限界, 日本不正脈心電学会, Vol.35, No, 2, 2015, pp.149-155
- [5] 原 聡 : 機械学習における解釈性, 人工知能, Vol.33, No.3, 2018, p.366-369
- [6] S.Kiranyaz et al. : Convolutional Neural Networks for Patient Specific ECG Classification, 37th Annual International Conference

- of the IEEE Engineering in Medicine and Biology Society, 2015, pp.2608-3611.
- [7] 尾亦 範泰他, 深層学習を用いた心電図波形の長期変動パターン抽出法, 人工知能学会全国大会論文集, 2018, 2H204.
  - [8] “MIT-BIH Arrhythmia Database” .  
<https://physionet.org/content/mitdb/1.0.0/> (参照 2020-2-19)