

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

Extracting Long-term Patterns from Electrocardiogram Waveform using Deep Learning

尾亦 範泰^{*1} 中村 嘉宏^{*2} 白山 晋^{*1}
Noriyasu Omata Yoshihiro Nakamura Susumu Shirayama

^{*1}東京大学大学院工学系研究科 ^{*2}東京大学工学部
School of engineering, The University of Tokyo Faculty of engineering, The University of Tokyo

Automatic analysis of electrocardiograms (ECG) has been attempted. Although almost all methods pay attention only to short-term waveforms, their changes over time are said often important in diagnosis. In this paper, we focus on such long-term waveform change and propose a method to extract it as a pattern. The proposed method combines a method of expressing time series data as a trajectory in a feature space and feature extraction by an autoencoder. Evaluation experiments suggested the existence of regularity in the pattern and its association with the disease.

1. はじめに

Internet of Things (IoT) に注目が集まり、これまで入手困難だったデータの取得が可能となりつつある。医療の領域でもウェアラブルデバイス等によって収集されたリアルタイムでの生体情報の有効活用が期待されている。特に注目されている分野の1つとして心電図のリアルタイムモニタリングがあげられる [高橋 17].

心電図自体の取得は容易になっているものの、検出した波形から得られる情報の分析手法、活用法に関しては依然として未開な部分が多い。基本的なものは周波数解析に基づくものであり、フーリエ分析やウェーブレット分析に基づくものが既に広く用いられている [宮内 16]. しかしながら、平岡によれば、心電図の診断は生化学的な検査とは異なり、定性的な判断による部分が大きく、数字で表しにくい波形の違いという指標を基準に行われる。そのため、定量的な判断指標が存在せず、コンピュータの得意な領域とは言いがたく、自動解析が難航している [平岡 15].

そこで、従来の周波数解析に寄らない方法で心電図波形を解析する研究が行われている。特に、近年の深層学習 (Deep Learning) の発展を受け、心電図に対しても適用する研究がなされている。Rajpurkar らは、畳み込みニューラルネットワーク (CNN) を用いた不整脈検知を行った [Rajpurkar 17]. 彼らは、ウェアラブルの単極誘導心電モニタを使用することで、過去の研究で用いられてきた心電図のデータセットと比べてサンプル数が 500 倍以上のデータセットを作成した。このデータセットを用いて訓練された CNN は、不整脈検知の再現率、及び精度の両面で認定心臓専門医に勝る能力を持つことを示している。彼らの結果から、ラベル付きデータセットの作成が問題になるものの、CNN による心電図解析が有効であることが分かった。

また、高橋らは、教師無し学習である Stacked Convolutional Denoising Autoencoder (SCDAE) を用いて、心電図からの特徴抽出を行うことを提案している [高橋 17]. 彼らは、SCDAE によって抽出された特徴量に対して、教師あり学習によって分類器を学習することで、直接的に心電図波形に対して分類器を学習する手法よりも高精度に不整脈を検知することに成功した。彼らの研究によって、ディープオートエンコーダを用いる

ことで、観測対象および心拍変動による波形変化に対してロバストな特徴抽出が可能であることが示された。

ところで、これらの手法は「1 秒」や「1 拍」といった短時間のデータにおける不整脈の検知を行っている。しかしながら、心電図は経時的な変化を見ないと診断が困難である場合がしばしばあり [平岡 15], 長時間での変動を観察する必要がある。短期間の心電図のみに着目し、長時間での変動を考慮しない従来手法では、そのような長時間の変動に基づく疾病予測への適用は難しい。

以上を踏まえ、本稿では、ある程度の長時間における、心電図波形の変動を把握するための手法を提案する。この手法では、CNN ベースのディープオートエンコーダによって抽出される特徴量をもとに、長時間での心電図波形における変化を、特徴空間における軌跡として表現し、パターンとして抽出する。提案手法は教師無し学習であるため、心電図に対して心拍間隔の明示や不整脈の有無や種類によるラベル付けを必要としない。さらに、公開されている心電図のデータセットに対して、この手法を適用した結果を示す。実験の結果、長時間での心電図波形の変化は、複数のクラスに定性的に分離できることが示された。さらに、訓練に使用しなかったデータから、データセットにおいて特異な疾病をもつ患者を、その心電図波形の軌跡の特異性から定性的に発見できた。このような結果から、本提案手法が心電図波形の長期変動の解析に有効であることが示される。

2. 提案手法

2.1 手法の概要

動的ネットワークの時間変化を把握する方法として、動的ネットワークを特徴空間における軌跡として表現する手法が提案された [van den Elzen 16]. この手法では、各瞬間のネットワークを主成分分析等を用いて低次元化する。この低次元量を時間的に連続的にプロットすることで、時間変化を表現することが可能となる。本稿では、この手法とオートエンコーダによる特徴抽出 [高橋 17] を組み合わせることで、心電図波形の長時間での変化を軌跡として表現することを提案する。

提案手法は、訓練フェーズと適用フェーズに分割される。訓練フェーズは、事前に与えられた心電図データをもとに、学習器のパラメータを調整するフェーズである。このフェーズでは、オートエンコーダのパラメータと、主成分分析の変換行列




図 1: 提案手法における適用フェーズの概要

が学習される。

適用フェーズは、初めて与えられる未知のデータに対して、訓練フェーズで学習した内容をもとに、実際に可視化を行うフェーズである。このフェーズは、図 1 に示すように、下記の 3 ステップで構成される。

1. 入力データからの固定長データの切り出し
2. オートエンコーダによる各データの低次元化
3. 低次元化されたデータの特徴空間への写像

以下では、各フェーズにおけるそれぞれのステップについて説明する。

2.2 固定長データの切り出し

個人 β の心電図波形データ \mathbf{x}^β をスライド窓方式で固定長 τ で区間に分割し、

$$\mathbf{x}^\beta = (\hat{\mathbf{x}}_1^\beta, \dots, \hat{\mathbf{x}}_R^\beta) \quad (1)$$

とする。ここで、 $\hat{\mathbf{x}}_r^\beta$ は個人 β の r 番目の区間、 R は区間総数である。なお、 τ はパラメータとして与える。

この方法で分割された固定長のデータは、心拍間隔や不整脈に対するラベルを考慮しない。このため、データに対してそのようなラベル付けを行う必要がなく、取得されるデータの利用が容易であるといえる。

2.3 オートエンコーダによる特徴抽出

提案手法では、入力を $\hat{\mathbf{x}}_r^\beta$ ($\beta = 1, \dots, M, r = 1, \dots, R$) とする、CNN ベースのディープオートエンコーダを用いる。図 2 に示すように、オートエンコーダを用いることで、データを表現する情報を保持する低次元な特徴量を得ることができる。

オートエンコーダのエンコーダ部を $\text{encoder}(\cdot)$ 、デコーダ部を $\text{decoder}(\cdot)$ で表す。各個人 β の r 番目の区間の特徴量は、

$$\mathbf{z}_r^\beta = \text{encoder}(\hat{\mathbf{x}}_r^\beta) \quad (2)$$

で表される。また、低次元特徴量であるエンコード結果 \mathbf{z}_r^β に対して、デコーダを作用させた結果

$$\hat{\mathbf{y}}_r^\beta = \text{decoder}(\mathbf{z}_r^\beta) \quad (3)$$

は、元信号 $\hat{\mathbf{x}}_r^\beta$ に類似したものとなる。

これを実現するため、訓練フェーズでは、訓練データに含まれる全ての個人に対する、時間区間分割された全データに対す

る絶対復元誤差の総和

$$E = \sum_{\beta=1}^M \sum_{r=1}^R |\hat{\mathbf{x}}_r^\beta - \hat{\mathbf{y}}_r^\beta| \quad (4)$$

を損失関数として、パラメータの学習を行う。

適用フェーズでは、各個人から取得されるデータ $(\hat{\mathbf{x}}_1^\beta, \dots, \hat{\mathbf{x}}_R^\beta)$ に対し、特徴量の系列 $(\mathbf{z}_1^\beta, \dots, \mathbf{z}_R^\beta)$ を得る。

2.4 特徴量にもとづく軌跡の描画

提案手法では、特徴量の系列を 2 次元空間に連続的に写像することで、元データの時間変化を可視化する。写像の手法として、先行研究 [van den Elzen 16] に倣い、主成分分析を用いる。この写像は、変換行列 W を用いて、 $\mathbf{p}_r^\beta = W\mathbf{z}_r^\beta$ と表される。変換行列 W は、訓練フェーズにおいて、すべての訓練データに対する特徴量を用いて学習される。

適用フェーズでは、各個人の特徴量系列 $(\mathbf{z}_1^\beta, \dots, \mathbf{z}_R^\beta)$ に対して、訓練フェーズで学習した変換行列 W を作用させることで、主成分スコアの系列 $(\mathbf{p}_1^\beta, \dots, \mathbf{p}_R^\beta)$ を得る。さらに、第 1 主成分スコアを x 軸に、第 2 主成分スコアを y 軸にして、この系列をプロットする。このプロットの位置は、時間経過とともに移動し、各個人について個別の軌跡を描く。この軌跡によって、心電図波形の変化が可視化される。

3. 数値実験

提案手法の有効性を確認するための数値実験を行った。

本研究では The MGH/MF Waveform Database^{*1} から取得した心電図波形のデータセットを利用した。このデータセットのうち、欠損値を含まないもののみを用いた。また、このうち 106 サンプルの 3 誘導心電図波形データを使用した。さらに 8 割を訓練データ、残り 2 割をテストデータとして実験を行った。

本実験においては、 $\tau = 0.6$ とし、サンプル 1 人の 0.6 秒分に相当する 216 次元 \times 3 チャンネルのデータを切り出した。また、スライド窓法におけるスライド幅は窓幅と一致させた。

本実験において用いたディープオートエンコーダの構成を表 1 および図 2 に示す。表 1 における Pool-3 層を、オートエンコーダによって得られる特徴量とした。これによって、各窓の 216 \times 3 次元のデータは、18 \times 4 = 72 次元にまで次元削減される。

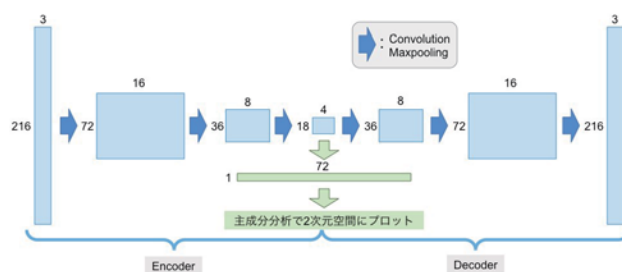


図 2: 実験における低次元化の概要

オートエンコーダによる次元削減によって情報量が大きく失われないことを確かめるため、特徴量をデコードした結果 $\hat{\mathbf{y}}_r^\beta$ をプロットし、元信号 $\hat{\mathbf{x}}_r^\beta$ と比較した。未知データに対する結

*1 <https://physionet.org/physiobank/database/mghdb/>

表 1: 実験に用いたオートエンコーダの構造

Name	Shape	Operation performed
Input	216 × 3	—
Conv-1	216 × 16	3 × 16 convolution
Activate-1	216 × 16	ReLU activation
Pool-1	72 × 16	3 maxpool
Conv-2	72 × 8	3 × 8 convolution
Activate-2	72 × 8	ReLU activation
Pool-2	36 × 8	2 maxpool
Conv-3	36 × 4	3 × 4 convolution
Activate-3	36 × 4	ReLU activation
Pool-3	18 × 4	2 maxpool
Conv-4	18 × 8	3 × 8 convolution
Activate-4	18 × 8	ReLU activation
Upsample-4	36 × 8	2 upsampling
Conv-5	36 × 16	3 × 16 convolution
Activate-5	36 × 16	ReLU activation
Upsample-5	72 × 16	2 upsampling
Conv-6	72 × 3	3 × 3 convolution
Output	216 × 3	3 upsampling

果の例を図 3 に示す。波形の特徴を維持して復元されており、特徴の保持に成功していると考えられる。

さらに、オートエンコーダによって得られた特徴量を、主成分分析によって写像した。写像の結果の例を図 4 に示す。各個人のデータに対する写像の結果を俯瞰して比較したところ、軌跡の形状はおおまかに定性的に 4 つのクラスに分類されることが分かった。これらのクラスを表 2 に示す。さらに、図 4 において、(a) は収束型、(b) は拡散型、(c) は直線型、(d) は曲線型の典型例をそれぞれ示している。軌跡の形状が明らかに特徴的で、パターンごとの分類が可能であり、何らかの規則性が見出せる可能性がある。

また、適用フェーズにおいて用いたデータのうち、その軌跡の形状が特異なものが定性的に発見された。このデータの軌跡は、上記の 4 つのクラスに分類できず、かつ軌跡の描かれる範囲が突出して大きい。図 5 にそのサンプル mgh126 の心電図波形の一部 (1000 秒から 1010 秒) と、特徴空間への写像を示す。データセットに示されている患者ごとの説明によれば、この患者は骨盤腔内腫瘍を患い、子宮の摘出及び卵巣の摘出を行っていた。用いたデータセットにおいて、骨盤腔内腫瘍を持つ唯一の患者であり、子宮の摘出及び卵巣の摘出を行った他の事例も本データセットには存在しなかった。この結果より、提案した手法によって心電図から疾病予測を行うこともできる可能性が示唆された。

表 2: 軌跡の定性的形状に基づく分類

名前	定義	個数
収束型	おおそ原点の位置に収束している	46
拡散型	相対的に広範囲に軌跡が拡散している	18
直線型	軌跡が直線状に重なっている	7
曲線型	軌跡が弓なりの曲線状に重なっている	10
例外	上記の分類に当てはまらない	3

4. 結論

本研究では、心電図波形データの分析が難航していることに言及し、観測対象及び心拍変動による波形変化の問題を解決する、心電図からの新しいパターン抽出手法を提案した。

提案手法は、心電図の長時間の波形を固定長に切り出し、それぞれを CNN ベースのディープオートエンコーダによって低次元化し、さらに主成分分析で 2 次元の特徴空間に連続的に写像を行うことで、心電図波形の長時間での変化をパターンとして可視化、抽出するものである。本手法は、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可能であり、長時間での変動に基づく心電図の分析を行うことができる。

提案手法の有効性の確認のために行った実験によって、心電図波形は大きめに 4 つのクラスに定性的に分類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することができた。したがって、特徴空間への写像結果と疾病とのつながりを明確に見出すには至らなかったが、何らかの規則性や関連性を見出せる可能性が示唆された。

今後の課題として、結果の解釈を定量化することが挙げられる。定性的に行われている軌跡の分類や例外の判別を、客観的指標に基づいて行えるようにする必要がある。これらは、軌跡データマイニングの手法をもとにしたクラスタリングや、ロバスト主成分分析などの外れ値検出手法を用いることで達成可能であると考えられる。さらに、現状の教師なし学習にもとづく方法では、得られる軌跡に「意味」を持たせることは困難である。より解釈性を高める方法として、データの一部または全部に対してラベルを付与することにより、半教師あり学習または教師あり学習の枠組みを用いた特徴量を用いる方法が考えられる。これによって、軌跡を描く特徴空間内において不整脈の判別境界を描画するといった、より客観的な方法によって結果の解釈が行えるようになると考えられる。

参考文献

- [Rajpurkar 17] 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)
- [van den Elzen 16] van den Elzen, S., Holtén, D., Blaas, J., and van Wijk, J. J.: Reducing snapshots to points: A visual analytics approach to dynamic network exploration, *IEEE Transactions on Visualization and Computer Graphics*, Vol. 22, No. 1, pp. 1–10 (2016)
- [宮内 16] 宮内 靖史, 植竹 俊介: 心電図の周波数解析の立場から, 心電図, Vol. 36, No. 2, pp. 161–166 (2016)
- [高橋 17] 高橋 終, 落合 桂一, 深澤 佑介: 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, 情報処理学会研究報告, Vol. 2017-DPS-171, No. 25 (2017)
- [平岡 15] 平岡 昌和: 心電図自動診断の限界, 心電図, Vol. 35, No. 2, pp. 149–155 (2015)




図 3: 未知データに対するオートエンコーダによる特徴量からの元信号の復元例。

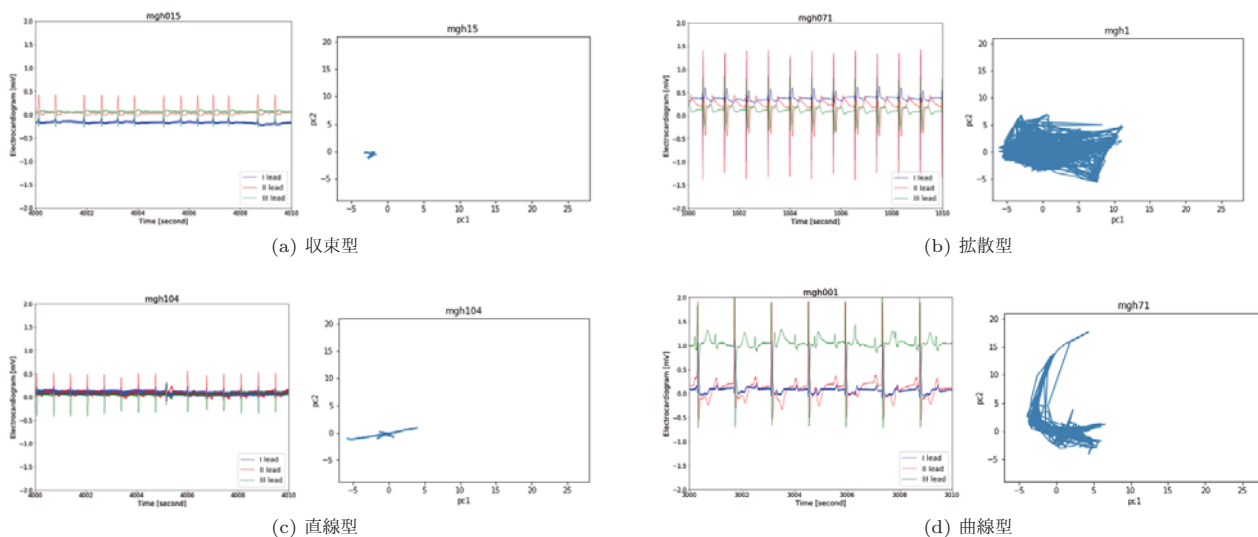


図 4: 提案手法によって描かれた軌跡の例. 4つのクラスの典型的な例を示した. 左側は信号の一部, 右側は得られた軌跡を示す.

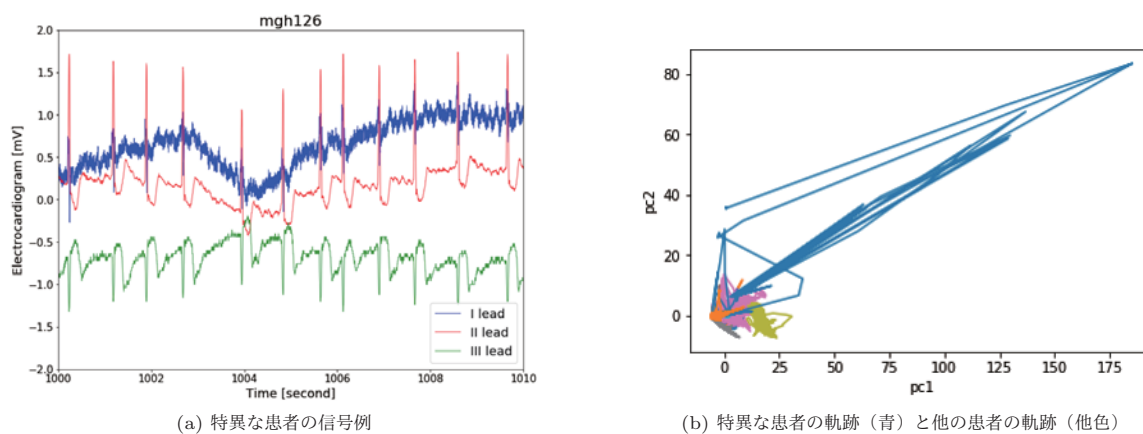


図 5: 定性的に発見された特異な患者に対する結果