

# 1 次元畳み込みによる心電位予測手法の提案

## Proposal of prediction method of ECG via 1D-CNN

清水 茂樹<sup>\*1</sup>  
Shimizu Shigeki

穴井 晃太<sup>\*1</sup>  
Anai Kouta

山田 直人<sup>\*1</sup>  
Yamada Naoto

<sup>\*1</sup> トヨタテクニカルディベロップメント株式会社  
Toyota Technical Development Corporation

Recently, the ECG (Electro Cardio Gram) has attracted to estimate human condition, such as fatigue and stress. Measuring the human biological data for a long time it takes physical and mental load. In this paper, we propose a method to predict long-term ECG data based on short-term data. The typical methods such as LSTM are generally used to predict time series data. The target ECG is characterized by fluctuation in period and voltage, and it is required to predict fluctuating data. So, we evaluated a 1 Dimension Convolution Neural Networks method using a filter size that matches the frequency characteristic of ECG. We showed that the method can be predicted more accurately than the LSTM. This result suggests that it can be an effective means when predicting long-term data.

### 1. まえがき

近年,人間の疲労やストレスを測るために心電位が注目されている[森 2009].疲労やストレスは,大量の心電位を用いて機械学習や深層学習のアルゴリズムによる推定が行われている.[下田 2016]このアルゴリズム開発には,心電位の時系列データを必要とするが,心電位を計測するセンサは長時間装着している場合,人の動きを制限し身体的・精神的負担が大きくなる.[濱谷 2015]そこで,短時間データから長時間データを予測生成する技術が求められている.

一方,時系列データの予測生成には,深層学習による予測生成が注目されている.これまで予測生成に用いられている深層学習は LSTM (Long Short Term Memory)などの手法が一般的である.[松井 2017][Chen 2015]しかし,これらの手法は学習データが長時間データで行われているケースであり,短時間データで学習,予測されているケースは少ない.

そこで本研究の目的は,短時間データの特徴を学習し,特徴を保持した長時間データの予測生成を行うこととする.本研究で予測生成する対象データは,心電位とし,心電位の周波数の特徴を活用し,周波数特性に応じたフィルターを使用する 1 次元畳み込み手法を提案する.

### 2. 実験方法

本実験の流れを示す. 被験者の心電位を計測する.被験者は 20 代成人男性 1 名で実施した計測時間は 5 s とし,5 s 間のデータの学習を実施した.被験者にはなお,実験に先立ち,当社内でプロジェクト実施許可申請の許可を得た上で,各被験者に対し実験に際するリスクを説明し,インフォームドコンセントを得た.

#### 2.1 計測器

図. 1 に示すようにセンサは市販のディスポーサブル電極を使用し,その取り付け位置は被験者の左胸部近辺に心臓を挟むように取り付けた.学習データを一度に多く獲得するため,電極を 3 つ貼り付けた.無線アンプは自社開発製品の Livo (生体信号記録システム)を使用し,計測は 100 Hz のサンプリングレートで実施した.計測された心電信号について,0.4 ~ 50 Hz

のバンドパスフィルタを用いて前処理を行い,筋電由来のノイズや呼吸由来のノイズを低減させた.




図.1 生体センサ装着 イメージ図

#### 2.2 学習データ

本研究では取得データを以下のステップで解析を実施した.(1)筋電や呼吸由来のノイズ除去のため,0.4 Hz ~ 50 Hz のバンドパスフィルタ処理を行う.(2)心電図の波形を 0~255 までの 256 点と 256~271 の 16 点に分離する.(3)256 点と 16 点をそれぞれ学習データと正解データとして格納する.(4)データを 1 サンプリングごとにシフトする.

### 3. 従来手法

これまで時系列データの学習には RNN が一般的に用いられてきた. RNN は,前回の出力を現在の入力に追加するものである.LSTM は RNN の発展系であり,長時間データの学習を可能にしている.[Hochreiter & Schmidhuber 1997] LSTM のネットワークは,入力層,中間層,出力層から構成され,中間層が LSTM から構成されるものである.本報告では LSTM のブロックを 1 層導入したモデルを用いて評価を実施した.

### 4. 提案手法

本研究で提案する 1 次元畳み込みによる予測手法は,畳み込みにおけるフィルターサイズを決める必要がある.フィルターサ

連絡先: トヨタテクニカルディベロップメント株式会社 清水茂樹  
〒 470-0334 愛知県豊田市花本町井前 1-9  
E-mail: shigeki.shimizu@mail.toyota-td.jp

イズは、ターゲットとなる心電位の周波数解析による結果と照らし合わせ決定した。今回は 50,25,12.5,6,4 Hz 相当の 1 次元畳み込みフィルタを設定し、それぞれ独自に畳み込みを行うように Inception モジュールを設計した。モデル概要を図.2 に示す

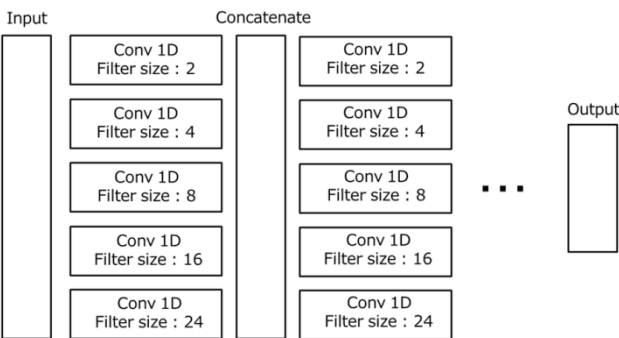


図.2 1次元畳み込みネットワークモデル概要

従来手法と提案手法を確認する検証方法として、人間の実測値との比較を実施した。心電位の解析は一般的にピーク波となる R 波の間隔である RRI (Rwave Rwave Interval)を用いられる。RRI の逆数が心拍数となるため、心拍数の平均・ゆらぎを用いて比較を実施した。[Akselrod 1981]予測生成したデータの平均・ゆらぎが人間のデータに近いほど優勢であると判断をする。

5. 結果

各手法を用いた心電位の学習、予測結果を図.3(a)(b)に示す。




図.3 各手法における予測結果

LSTM による予測結果では、心拍ゆらぎは発生せず、一定の周期で信号生成されている。これは、学習データに用いるデータ数が短時間分 (5 s ≒ 4~5 波形) による影響が大きいことが考えられる。1 次元畳み込みによる予測結果は、ピーク間隔のゆらぎを保持したデータ生成が出来ている様に見受けられる。また、心電位のピーク値についてもゆらぎを確認することが出来た。

表.1 LSTMと1次元畳み込みにおける比較

	心拍数平均	心拍数分散
LSTM	62.5	0.3
1次元畳み込み	56.3	6.3
(参考)人間実測値	58.8	4.0

人間の実測値との比較結果を表.1 に示す。LSTM では、短時間データによる学習ではゆらぎが発生しない。一方、提案手法である 1 次元畳み込みによる手法では、5 s ≒ 4~5 波形の短時間データで学習、予測を行った結果、ゆらぎを保持したデータの予測生成が行われている。この結果が示すように、人の心拍数平均、ゆらぎと比較しても同程度の平均、分散と遜色ない結果となった。

6. まとめ

本研究における提案手法である 1 次元畳み込みによる時系列データの予測生成は、従来手法の LSTM より高精度にゆらぎを持ったデータの生成が行える可能性があることを示した。長時間データを用いた学習・推論である場合には LSTM の方が優位な場面も想定されるが、今回のターゲットのように短時間データで長時間データを予測生成する場合に有効な手段となりうることを示唆する。本研究では被験者 1 名のデータでの実験のため、今後は被験者数を増やし検証していく必要がある。

参考文献

[森 2009] 森 信彰: 心拍変動による精神ストレスの短時間解析に関する研究, 年次大会講演論文集, 日本機械学会, 2009.

[下田 2016] 下田 宏: 生理指標計測による心理活動推定の問題, 人間工学 52(Supplement), 日本人間工学会, 2016.

[濱谷 2015] 濱谷尚志: 種々のセンサを併用した集中度センシング法の検討, 研究報告高度交通システムとスマートコミュニティ (ITS), 情報処理学会, 2015.

[松井 2017] 松井 藤五郎: LSTMを用いた株価変動予測, 人工知能学会全国大会論文集, 人工知能学会, 2017.

[Chen 2015] K.Chen: A LSTM-based method for stock returns prediction: A case study of China stock market, 2015 IEEE International Conference on Big Data (Big Data), Santa Clara, CA, pp. 2823-2824, 2015.

[Hochreiter 1997] Hochreiter: Long Short Term Memory, Neural Comput., Vol. 9, No. 8, pp.1735 - 1780, November 1997.

[Akselrod 1981] Akselrod: Power spectrum analysis of heart rate fluctuations: quantitative probe of beat-to-beat cardiovascular control, Science, 213, 220-222, 1981.