

心の健康状態の評価に向けた気分変化を伴う心電図の特徴抽出

Feature Extraction of ECG Affected by Mood Change: towards mental states estimation

北河 茜 † 加藤 昇平 †
Akane Kitagawa Shohei Kato

1 はじめに

うつ病等の気分障害の患者は増加しており、これらの病の予防、早期発見には日々の心の健康状態を把握することが必要であると考えられる。心の状態の評価に関する研究は盛んに行われている [1][2] が、近年ではウェアラブルデバイス等により簡便に取得できる生体情報の活用が期待されている。生体情報の中でも、心電図は実用性・普及性の面で優れており、大橋ら [3] は快・不快イメージ時の心拍変動と心電図のカオス解析に基づいて心の状態を快・不快・平静に分類した。大橋らはイメージによる心の状態の変化を心電図によって捉えられる可能性を示唆したが、快・不快を指定してイメージさせることは、本来の心の状態に反したイメージをさせることになり、日々の心の健康状態の把握に向けては実用的ではない。そのため、著者ら [4] は本来の心の状態を反映した心電図を採取するため、自身の近い未来を想像した時の心電図測定し、心拍変動指標から特徴量を抽出し、機械学習を用いた心の健康状態の推定手法を提案した。しかし、4 段階の心の健康状態の推定は正答率 50 % 程度しか得られておらず、高い性能とは言えない。

また、深層学習の発展を受け、心電図波形からの特徴抽出にも Deep Autoencoder が応用されている。高橋ら [5] は Stacked Convolutional Denoising Autoencoder (SCDAE) を用いて心電図から特徴量を抽出し、短時間データにおける不整脈を検知している。さらに、尾ら [6] は高橋らと同様に短時間データから Deep Autoencoder により抽出した特徴量を、主成分分析を用いて低次元化し連続的にプロットすることで、心電図波形の長時間の変化を軌跡として表現する手法を提案した。尾らは手法の有効性の確認に、病院で測定されたデータ (MGH/MF Waveform Database) を用い、心電図波形の長期パターンはおおまかに 4 パターンに分類可能と示唆しているが、各パターンに対応する症候群や疾病については明らかでない。

そこで、本稿では心の健康状態評価の性能を向上するため、Deep Autoencoder を用いて心電図から新たな特徴量を抽出し、さらに、気分変化と特徴量の関係について考察する。図 1 に概要を示したように、近い未来想像時の心電図データから心の健康状態を評価するための特徴抽出手法として Convolutional Autoencoder (CAE) と t-distributed Stochastic Neighbor Embedding (t-sne) を組み合わせた手法を提案する。

2 特徴抽出手法

2.1 CAE を用いた特徴量抽出

Convolutional Autoencoder (CAE) は畳み込み層によって構成される Autoencoder である。Autoencoder は入力層と出力層は同次元であり、入力層より小さい次元の中間層を通り、入力データを教師データとして学習を行う。そのため、中間層において入力データの情報を保った入力層より小さな次元のデータが得られる。

CAE への入力は、心電図の波形データをスライディングウィンドウ方式で切り出したデータとする。協力者 p の T [sec] の心電図波形データをスライド幅 S [sec]、ウィンドウ幅 W [sec] で分

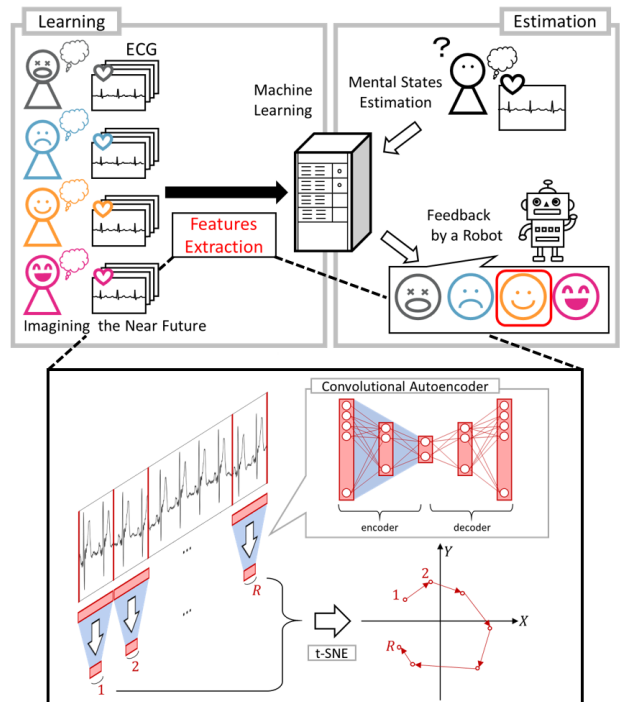


図. 1 研究概要

割すると、1 人あたりのサンプル数 N は下式で示される。

$$N = \frac{T - W}{S} + 1 \quad (1)$$

サンプル数 N の協力者 p のデータのうち、時系列に沿った W/S サンプルごとのデータ (総数 R) から特徴量を抽出するため、残りのデータをトレーニングデータとする。

トレーニングデータを用いて学習した CAE に M 名の協力者のデータ $\hat{\mathbf{x}}_n^p (p = 1, \dots, M, n = 1, \dots, R)$ を入力し、特徴量を得る。協力者 p の r 番目のサンプルの特徴量 \mathbf{z}_r^p 、デコーダ結果 $\hat{\mathbf{y}}_r^p$ は、CAE のエンコーダ部を $\text{encoder}()$ 、デコーダ部を $\text{decoder}()$ とすると、下式で示される。

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

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

協力者 p のデータ ($\hat{\mathbf{x}}^p, \dots, \hat{\mathbf{x}}_R^p$) に対して、特徴量 ($\mathbf{z}_1^p, \dots, \mathbf{z}_R^p$) が得られる。

2.2 t-SNE を用いた次元圧縮

オートエンコーダにより抽出した特徴量を t-distributed Stochastic Neighbor Embedding (t-SNE)[10] を用いて圧縮し、2 次元空間上に連続的にプロットすることで、心電図の時間変化を可視化する。t-SNE は高次元の類似度が反映されるように最適な低次元に埋め込む手法であり、高次元空間の類似度を正規

† 名古屋工業大学, Nagoya Institute of Technology




図. 2 測定配置図




図. 3 心電図測定の構成

分布, 低次元空間の類似度を自由度 1 の t 分布で表現し, それらの距離を最小化するように確率分布のパラメータを最適化する.

協力者 p の特徴量 $(\mathbf{z}_1^p, \dots, \mathbf{z}_R^p)$ の類似度は下式の正規分布 p_{ij} で表現される.

$$p_{ij} = \frac{p_{ji} + p_{ij}}{2R} \quad (4)$$

$$p_{ji} = \frac{\exp(-\|\mathbf{z}_i^p - \mathbf{z}_j^p\|^2 / 2\sigma_i^2)}{\sum_{k \neq i} \exp(-\|\mathbf{z}_i^p - \mathbf{z}_k^p\|^2 / 2\sigma_i^2)} \quad (5)$$

ここで, σ_i はパラメータである. さらに, 低次元空間 $(\mathbf{t}_1^p, \dots, \mathbf{t}_R^p)$ の類似度は下式の自由度 1 の t 分布 q_{ij} で表現される.

$$q_{ij} = \frac{(1 + \|\mathbf{t}_i^p - \mathbf{t}_j^p\|^2)^{-1}}{\sum_{k \neq i} (1 + \|\mathbf{t}_i^p - \mathbf{t}_k^p\|^2)^{-1}} \quad (6)$$

p_{ij} q_{ij} が近づくように, カルバック・ライブラー (KL) 情報量を損失関数 C として, C が最小となるように, 最急降下法によって圧縮後の点 \mathbf{t}_i^p を更新する. 損失関数 C は下式で示される.

$$C = KL(P, Q) = \sum_i \sum_j p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (7)$$

協力者ごとに t -SNE によって圧縮された特徴量 $(\mathbf{t}_1^p, \dots, \mathbf{t}_R^p)$ が得られる.

3 心電図データ採取

本研究は, 名古屋工業大学生命倫理審査委員会により承認されている (承認番号 30-018). 本研究は先行研究 [4] にて採取した心電図データを用いるが, 採取方法はデータを扱う上で重要であるため, 本章に再掲する.

3.1 未来想像時の気分変化

Rainville ら [7] は協力者に過去に感じた強い情動経験を想起させ生体信号の変化を測定し, 情動状態を推定する手法を提案した. 否定的な心の状態に焦点をあてた場合, 協力者が不快だと認識している経験を想起させることは酷であり, 倫理的に問題があると考えられる. 一方で, 勝俣ら [8] は時間的展望について, うつ病群は健常群に比べて過去・現在・未来をすべて否定的に認知していると指摘している. このことから, 心が健康でないときは, 全てを否定的に捉えてしまい, 未来について否定的な想像をすると考えた. よって, 本研究では近い未来想像時の気分変化, 心電図の変化に着目し, 心電図データの採取や特徴抽出を行う.

3.2 心電図測定方法

測定の協力者は, 心身ともに健康な 20 歳~25 歳の 23 名 (男性 22 名, 女性 1 名) である. 図 2 に測定環境を示す. 測定室の温度は 25 度, 測定時間帯は 15 時~18 時に統一する. さらに, 食事とカフェインの摂取は心電図に影響を与えるため, 測定の 2 時間前から控えてもらう. 協力者はリクライニングソファに座位でスクリーンに向かい, 右手首と左足首に電極を装着する. 使

表. 1 TMS の項目

下位尺度	項目
緊張	気がはりつめている
	そわそわしている
	気が高ぶっている
混乱	やる気が起きない
	集中できない
	頭がよく働かない
抑うつ	希望がもてない感じだ
	孤独でさびしい
	暗い気持ちだ
疲労	疲れている
	へとへとだ
	だるい
怒り	ふきげんだ
	腹がたつ
	むしゃくしゃする
活気	いきいきしている
	陽気な気分だ
	活気に満ちている

用する心電心拍モニターは株式会社クロスウェル製の HRR-01 である. 測定は図 3 で示す構成で, 最初に安静を 180 秒間測定する. この時, 協力者に安静を測定する意図が伝わらないよう機器の動作確認と説明する. その後, 「TMS_1」では質問紙に回答してもらい, 再び心電図の測定を開始し, 機器調整に 90 秒, 安静 (ダミー) 90 秒, 想像 180 秒, 安静 (ダミー) 90 秒の計 7 分 30 秒間で測定は終了する. 区間の切替はスクリーン画面と音で合図し, 測定者は心電図に影響を与えないように測定室から退出する. 心電図測定中はなるべく楽な姿勢で体動しないよう求め, 「想像」では自分のこれから 3 日間の近い未来のうち最も印象的な事柄を想像するように指示する. 最後に, 「TMS_2」で再び質問紙に回答してもらう.

「TMS_1」「TMS_2」では, 一時的気分尺度 (TMS) [9] に回答してもらう. TMS は POMS を参考に作成された質問紙で, POMS 同様に表 1 に示す 6 つの下位尺度から成る. TMS の回答形式は表 1 に示す各項目に, 「全くあてはまらない」から「非常にあてはまる」までの 5 件法で, 各項目の得点が高いほどそれぞれの下位尺度 (気分) が強くなるように 1 点から 5 点を与える. 3 項目の合計がそれぞれの下位尺度 (気分) の得点とされる. 「TMS_1」と「TMS_2」の得点の差をとることで, 近い未来を想像したことによる「気分変化量」を算出できる.




図.4 フィルタリング前後の波形の例




図.5 CAEによる元波形復元の例

4 特徴抽出実験

4.1 データの前処理

実験には、3章で示したデータのうち、近い未来想像時に気分が大きく変化した協力者7名のデータを用いる。この7名は「抑うつ」と「活気」の気分変化量により決定し、Positive群3名とNegative群4名から成る。各群の気分変化量の基準はPositive群は「抑うつ」-5以下または「活気」5以上、Negative群は「抑うつ」5以上または「活気」-5以上とした。各協力者のデータからそれぞれ動作確認と説明した3分間の心電図データ(安静データ)と近い未来の想像をさせた3分間の心電図データ(想像データ)を切り出し、併合して標準化した。これにより、想像データに安静データが反映される。

心電図波形には、高周波では筋電図ノイズや電力誘導障害、加算性白色ガウスノイズ、低周波では基線変動等の外部ノイズが含まれている可能性がある。そのため、0.2Hzから25Hzの帯域成分のみ通過するバンドパスフィルタを用いてノイズを除去した。図4にフィルタリング前後の波形の例を示したように、基線の揺れが取り除かれていることが確認できる。また、測定に使用した心電心拍モニターHRR-01はサンプリング周波数1000Hzであるが、簡便な携帯型心電計はサンプリング周波数250Hz~125Hzの機器が多い。よって、実用面を考慮して、フィルタリング後のデータは1000Hzから250Hzにダウンサンプリングした。

4.2 実験設定

前処理を施した各協力者の想像データは、区間切り替の前後5[sec]ずつのデータは除き、 $W = 1.5[sec]$, $S = 0.25[sec]$ として切り出して、1人あたりのサンプル数は $N = 675$ である。このうち時系列に沿った波形が重複しない6サンプルごとの113をテストデータ、残りの562をトレーニングデータとする。CAEは7名全員のトレーニングデータを用いて学習する。CAEへの入力 X は1.5[sec]のデータ $(375 \times 1 \times 1)$ である。実験に用いた畳み込みオートエンコーダの構成を表2に示す。エンコーダの最終層pool3 $(19 \times 1 \times 4)$ を結合し、76次元の特徴量が得られる。CAEを用いて抽出した特徴量はt-SNEを用いて次元を圧縮し、各協力者ごとに2次元空間上にプロットする。この時、各協力者の特徴量はt-SNEにより 2×113 まで圧縮され、時系列順にプロットすることで時間経過の情報が保たれる。

4.3 実験結果

CAEにより心電図波形の情報が大きく失われていないことを確認するため、CAEへの入力データとデコーダの出力を比較した。図5に入力した心電図波形データとデコーダの出力を重ね

表.2 CAEの構造

Layer	Type	Output Shape	Option
Conv1	convolution	$372 \times 1 \times 16$	kernel : 4×1 , stride : 1, ReLU
Pool1	max-pooling	$124 \times 1 \times 16$	kernel : 3×3
Conv2	convolution	$120 \times 1 \times 8$	kernel : 5×1 , stride : 1, ReLU
Pool2	max-pooling	$40 \times 1 \times 16$	kernel : 3×3
Conv3	convolution	$38 \times 1 \times 4$	kernel : 3×1 , stride : 1, ReLU
Pool3	max-pooling	$19 \times 1 \times 4$	kernel : 2×2
Dcnv1	deconvolution	$40 \times 1 \times 8$	kernel : 4×1 , stride : 2, ReLU
Dcnv2	deconvolution	$124 \times 1 \times 16$	kernel : 7×1 , stride : 3, ReLU
Dcnv3	deconvolution	$375 \times 1 \times 1$	kernel : 6×1 , stride : 3, ReLU

てプロットした例を示す。心電図において重要なP, Q, R, S, T波が確認でき、特徴を維持して復元できていると考えられる。よって、CAEにより抽出した特徴量は心電図の特徴を上手く低次元化できていることが示唆される。CAEによって抽出した特徴量をt-SNEにより圧縮し、協力者ごとにプロットした結果を図6に示す。これらの周期性と無秩序性を分析するため、埋め込み次元 $m = 3$ 、時間遅れ $\tau = 1.5[sec]$ として相関次元解析を行った。相関次元はしばしば脳波などの生体信号解析に用いられている[12]。図7にt-SNEにより圧縮した特徴量の各成分ごとの相関次元とこれらをAffinity Propagation (AP)を用いてクラスタリングした結果を示す。APによりクラスタ数3 (A, B, C)にクラスタリングされ、Negative-3を除いて、Negative群とPositive群はそれぞれクラスタを形成していることを確認した。この結果より、気分変化を反映した共通の特徴量を抽出できている可能性が示唆される。

Negative-3のみ異なるクラスタを形成し、他のNegative群と異なる周期性と無秩序性を示した。原因として、TMSの回答の意識的歪曲または本来の気分変化を主観的に捉えることができていない可能性が考えられる。これを調査するため、潜在的な気分を評価するIPANAT[11]を追加して用いることを考えている。

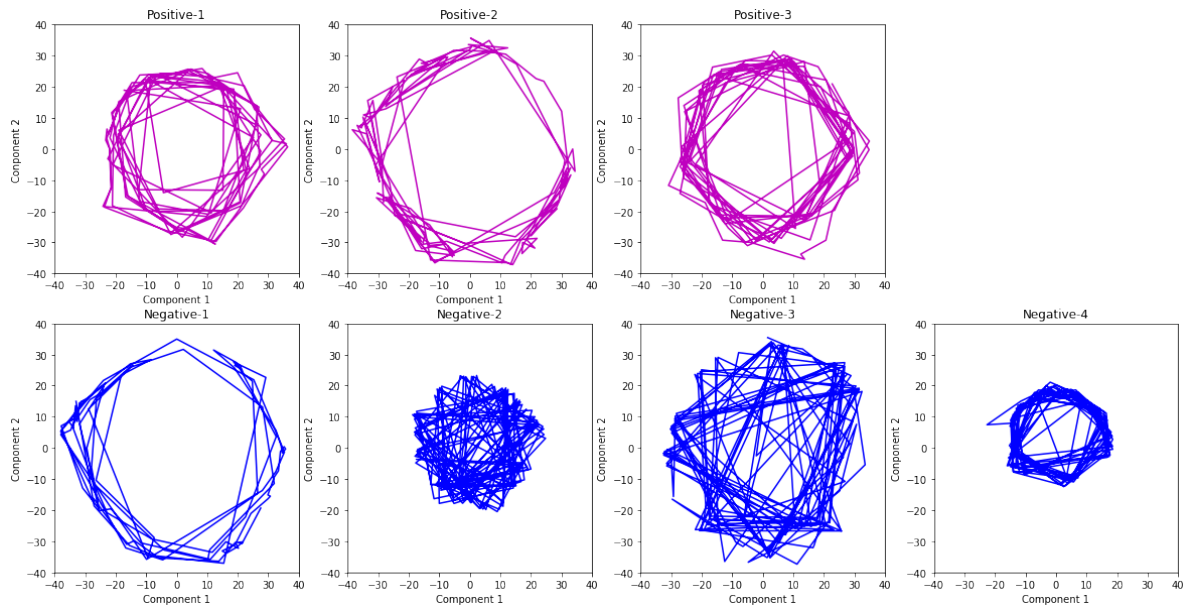


図. 6 t-SNE を用いて圧縮した心電図特徴量

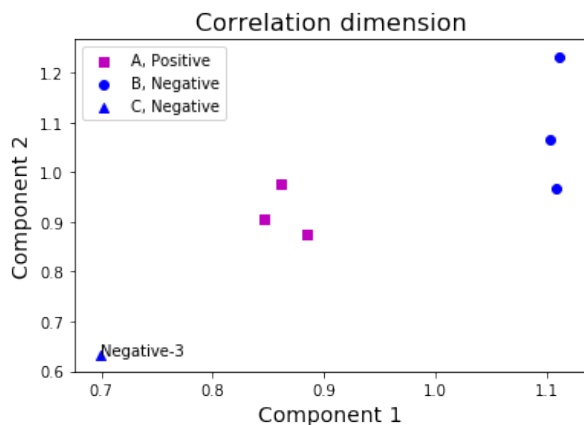


図. 7 t-SNE により圧縮した特徴量の相関次元

5 おわりに

本稿では、心の健康状態の推定に向けた特徴量の候補として、心電図の波形データから CAE と t-SNE を用いた特徴量を提案した。近い未来想像時に気分が大きく変化した協力者群の心電図データを用いた特徴抽出実験により、Positive 群と Negative-3 を除いた Negative 群の相関次元はそれぞれクラスを形成し、気分変化を反映した特徴量を抽出できている可能性が示唆された。今後の課題として、協力者数を増加して追加の検証をすること、提案手法により抽出した特徴量を用いて心の健康状態の推定を試みる事が挙げられる。

参考文献

[1] 丸山貴司, 笹本裕美, 荒川尚美, 川副智行, 中川匡弘: 脳波のフラクタル性を用いた感性推定精度の向上に関する研究, 電子情報通信学会論文誌 A, Vol. 95, No. 4, pp. 343–356

(2012).

- [2] Kinase, Y. and Venture, G.: Estimating mood variation from MPF of EMG during walking, *Engineering in Medicine and Biology Society (EMBC), 35th Annual International Conference of the IEEE*, pp. 4981–4984 (2013).
- [3] 大橋正, 神保直樹, 篠崎亮, 中川匡弘: 心拍変動と心電図のカオス解析に基づいた感性状態分類, 電子情報通信学会論文誌 A, Vol. 97, No. 7, pp. 538–552 (2014).
- [4] Kitagawa, A., and Kato, S.: Mental States Estimation Using ECG Affected by Mood Change During Imagining the Near Future, *IEEE 1st Global Conference on Life Sciences and Technologies*, pp. 91–92 (2019).
- [5] 高橋 稔, 落合 桂一, 深澤 佑介ほか: 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, 情報処理学会論文誌, Vol. 59, No. 12, pp. 2213–2220 (2018).
- [6] 尾亦 範泰, 中村 嘉宏, 白山 晋: 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, pp. 204–204 (2018).
- [7] Rainville, P., Bechara, A., Naqvi, N., and Damasio, A. R.: Basic emotions are associated with distinct patterns of cardiorespiratory activity, *International Journal of Psychophysiology*, 61(1), pp.5–18, 2006.
- [8] 勝俣 暎史, 松岡 奈緒: うつ病の時間的展望, 日本精神科診断学会 第 22 回論文集, pp. 72, 2002.
- [9] 徳田 完二: 一時的気分尺度 (TMS) の妥当性, 立命館人間科学研究, Vol. 22, No. 1, p. 6 (2011).
- [10] Maaten, Laurens van der and Hinton and Hinton, Geoffrey.: Visualizing data using t-SNE, *Journal of machine learning research*, Vol. 9, pp. 2579–2605 (2008).
- [11] 下田 俊介, 大久保 暢俊, 小林 麻衣, 佐藤 重隆, 北村 英哉: 日本語版 IPANAT 作成の試み, 心理学研究, Vol. 85, No. 3, pp. 294–303 (2014).
- [12] 伊賀崎 伴彦, 村山 伸樹: 味認知に対するヒト脳波のフラクタル次元解析, 電気学会論文誌 C (電子・情報・システム部門誌), Vol. 127, No. 10, pp. 1780–1786 (2007).