

容積脈波特徴量に基づくモバイルサービス利用時における 低次メンタル状態の推定

磯 俊樹^{1,a)}

概要: モバイルサービス利用時のユーザの反応を、ユーザに問い合わせることなく脈波データから自動的に獲得する方式を提案する。ここでのユーザの反応とは、集中や覚醒といった低次メンタル状態を指す。具体的には、低次メンタル状態がモバイルサービス利用時のユーザ反応と密接な関係があるという仮定の下、主観評価実験結果に基づいて得られる指標により表現する。また、入力には耳朶容積脈波から算出できる脈波特徴量を用いる。耳朶容積脈波を対象にしたのは、ウェアラブル型デバイス（眼鏡型スマートフォン）に脈波センサを搭載することで、スマートフォン操作等を妨げることなく、安定的に容積脈波を取得できるからである。耳朶容積脈波から算出される脈波特徴量と、主観評価実験結果に基づき得られる低次メンタル状態の写像関係を、カーネルベースの回帰手法であるガウス過程回帰モデルとサポートベクター回帰モデルを用いて構築したので、その結果について報告する。また、関連度自動決定法を用いて、低次メンタル状態の推定に有効な脈波特徴量についても分析したので、それについても報告する。

1. はじめに

サービス提供者にとって、コンテンツを集中して見ているのか、ただ漫然と見ているのか等、提供したサービスに対するユーザの反応を把握したいという要望は多い。特に、コンテンツに対するアンケート結果もサービス内容へのフィードバックとして有効であるが、それ以外の用途として、例えば、ユーザが集中して閲覧している場合にはバナー広告を抑制し、暇つぶしにインターネットをブラウジングしている場合には広告などの通知をするなど、サービス制御の分野でも利用できる。しかし、陽にユーザに低次メンタル状態を問い合わせること自体は現実的ではないので、低次メンタル状態との関連が高いユーザの反応を自動的に検出する方法が必要となる。そこで本論文では、脈波特徴量から低次メンタル状態を推定することに着目する。というのも、容積脈波は小型のセンサを用いて非侵襲で獲得することででき [1]、高齢者の痴呆 [2]、子供の精神状態 [3]、無呼吸器症候群の診断、さらには居眠り運転の検出 [4] など、医療分野は勿論のこと、それ以外の分野での実応用が検討されているからである。

非侵襲センサで獲得することができ、メンタル状態も推定できる容積脈波ではあるが、ユーザの行動を妨げないようにデータを取得することには課題がある。無呼吸器症候

群 [5],[6]、てんかんの診断、飲酒運転 [7] などの応用では、脈波センサを指先などに動かないように装着する必要がある。インタフェース上の課題が実応用の適用範囲を狭めていた。モバイルサービス利用時にユーザの低次メンタル状態に応じて広告などの通知を制御するサービスに適用するためには、このインタフェースの課題を克服する必要がある。サービス提供者がコンテンツに対するフィードバックを得るためには、アンケートをユーザに依頼することが主流となっている。しかし、そもそも、ユーザ自身、サービス利用時の感想を大局的に回答することはできても、どの部分でどのように感じたか等を振りかえることはユーザにとって非常に煩わしく、そもそも正確な回答を得ることが難しい。客観的な観点からユーザの反応を獲得するアプローチとして、サービスアクセスログからユーザがサイトに滞留した時間や視線情報を分析することにより興味を推定する手法も提案 [8] されている。前者はリアルタイム性がないのでサービス制御には適用できず、また、スマートフォン上に搭載したカメラで安定的に視線情報を取得するのも現実的ではない。

Y. Cho らがスマートフォンに搭載されたカメラ画像とサーマル画像を用いて容積脈波を取得し、それを解析することでストレス状態を抽出する手法を提案している。しかし、この手法では、計測時に顔や指の位置や動きに制約を与えているため、モバイルサービスを自由に利用している環境では適用できない。さらに重要なことは、そこで用い

¹ (株)NTTドコモ 先進技術研究所
3-6 Hikari-no-oka, Yokosuka, Kanagawa 236-8536, Japan
^{a)} isot@nttdocomo.com



図 1 耳朶脈波センサを搭載したウェアラブル型デバイス。

Fig. 1 Wearable device mounted on earlobe for plethysmogram capture.

ている脈波特徴量は心拍系特徴量だけなので、推定できるメンタル状態にも限界がある。容積脈波からは心拍系特徴量以外にも、LF/HF やカオスに関する特徴量 [3],[9] が抽出でき、実際に医療や心理分析に適用されている。もし、容積脈波がユーザに負担や制限をかけることなく取得できれば、低次メンタル状態が推定できるので有効な手法となる。低次メンタル状態は自律神経の影響に大きく依存しているため、血流のように自律神経によって制御されているものを計測することは有効である。しかし、低次メンタル状態を推定するために使われる脈波特徴量は様々であり、どのような脈波特徴量が低次メンタル状態の判定に有効なのかが明確になっていなかった。

そこで、次世代向けのスマートフォンの一つの形として提案したウェアラブル（眼鏡）型スマートフォン [10] を利用して容積脈波を検出する方法を提案する。容積脈波は、通常、指先のような指尖に装着することで計測するが、耳たぶのような体の末端である耳朶からも容積脈波は検出可能となる。すなわち、眼鏡型デバイスのツルの部分に脈波センサを搭載することで、ユーザがモバイルサービスを利用しているにもかかわらず容積脈波を取得することができる。本論文では、ユーザに制約を与えることなく取得できる耳朶容積脈波から低次メンタル状態を推定する手法を検討する。また、低次メンタル状態に有効な脈波特徴量についても分析する。次章では、まず、容積脈波から抽出する脈波特徴量と、低次メンタル状態に起因する感覚量を表す主観評価量について述べる。次に、脈波特徴量と主観評価量との写像関係を構築する手法として、カーネルベースの回帰モデルについて説明する。そして、実際にモバイルサービスを被験者に利用した際に得られた容積脈波ならびに主観評価の各データで提案モデルの評価をしたのでそれについても紹介する。

2. 低次メンタル状態推定のための特徴抽出

ここでは、容積脈波から脈波特徴量を算出する方法と、低次メンタル状態を決定するための主観評価について述べる。

2.1 低次メンタル状態を決定するための主観評価

前述の通り、サービスコンテンツに対するユーザの反応を測定することはデータの質の観点からも量の観点からも難しい。しかし、少なくともコンテンツに対する評価が肯定的であるとか否定的であるなど詳細な状態は分からなくとも、集中や覚醒等の低次メンタル状態がコンテンツに対するユーザ反応に寄与していると考えられる [11]。すなわち、サービスに対する主観評価量が大きく変わることは、低次メンタル状態も大きく変わるとの仮定をおく。そして、ここで扱う低次メンタル状態の推定は、集中や覚醒との個々の状態を推定することではなく、通常の状態から何がしかのメンタル状態が変化することに焦点を当てることとする。具体的には、主観評価における評価項目に依らず、主観評価のスコアが大きくなった場合に低次メンタル状態のスコアが大きくなるという仮定を置くこととする。

教師信号となるユーザの低次メンタル状態を規定するために、モバイルサービスに対するユーザの反応を主観評価実験より獲得する。具体的には、耳朶脈波センサを装着した被験者に、スマートフォンを使ってモバイルサービスを利用してもらい、その時の容積脈波を計測するとともに、ユーザの反応をスコア化することで実現する。被験者はユーザ 13 名で、日頃からスマートフォンを利用しているに依頼することで、操作の不慣れなどサービスコンテンツ以外のストレス要因を排除する。そして、利用してもらったモバイルサービスは、好みの映画、音楽、ゲーム、ならびにお気に入りのサイトと、生理的に受け入れにくいノイズ映像や不快な音声も視聴してもらいなど、嗜好が両極端になるものをサービス対象として選択した。特に、お気に入りのサイトに関しては、実験の数日間前から利用を控えてもらったり、癒し系の音楽を試聴してもらいなどユーザの反応がはっきりと表れるような条件を課した。なお、各モバイルサービスは 3 分から 15 分程度、利用してもらい、サービスの切り替えの際は、安静状態を 1 分間挟み、他サービスの余韻による影響を抑えるようにした。また、モバイルサービス利用直後に、タイムレコーダーが入ったビデオを見ながら評価実験を被験者に振り返ってもらい、5 秒間隔ごとに自ら自信を持ってサービスに対する反応があったと確信できる場合のみ、8 種類の評価項目に 7 段階で評価してもらった。

8 つ評価項目の関係を調べるために、同時刻のスコアをプロットすることで項目間の相関性を調べた。図 2 は、ある被験者に好みの映像を視聴して際の主観評価結果である。”interst（興味があった）”と”satisfaction（満足した）”の評価に相関が見られた以外、他の項目は全て互いのスコアと独立な評価をしていることが分かる。本論文で扱う低次メンタル状態は、何がしかのメンタル状態に変化を扱うことに焦点を置くので、時刻 t における k 番目の評価項目のスコア $Score_k(t)$ を線形結合して得られる総合点を低次メン

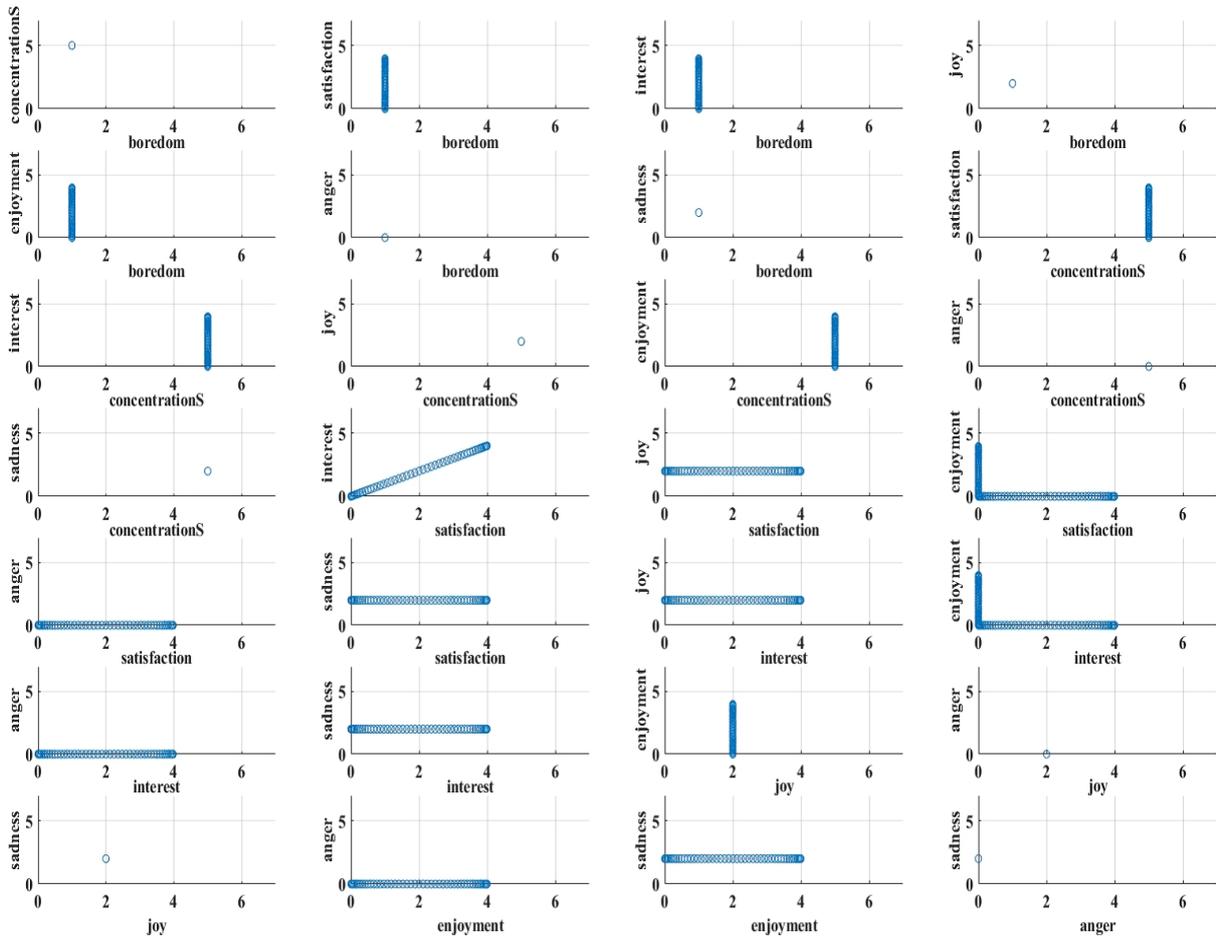


図 2 主観評価項目のスコア間の相関性.

Fig. 2 Linearity relations between subjective evaluation items.

タル状態の変化を表す指標 $y(t)$ として用いることとする.

$$y(t) = \frac{1}{(Sr * M)} \sum_{k=1}^M Score_k(t) \quad (1)$$

ここで、 M は評価項目の種類 (8 種類) を、また、 Sr はスコアを規格化する値 (最大スコア値 = 7) を表す.

2.2 脈波特徴量

前述の通り、被験者 13 名からモバイルサービス利用時の耳朶容積脈を取得する。この実験で用いた耳朶脈波センサは TAOS 製の機器を用いた。なお、図 3 は評価実験時の写真であるが、別の目的で脳波データも同時計測したために被験者の頭に電極を装着しているが、実際にモバイルサービス適用する場合は不要であるので、ユーザへの装着に対する負荷はない。ここで得られた耳朶容積脈波の波形を図 ?? に示す。この耳朶容積脈波から、以下に説明する 4 タイプの脈波特徴量を算出する。

タイプ 1: 加速度脈波系特徴量

はじめに、加速度脈波系特徴量の算出について述べる。加速度脈波は、耳朶容積脈波を時間で二階微分したものであり、この時の波形を図 4 に示す [12]。加速度脈波の波形に



図 3 耳朶脈波センサを装着してモバイルサービスを利用する被験者.
Fig. 3 Subject using mobile services with the earlobe plethysmogram device.

は 5 つの極値 (極大値ならびに極小値) が得られることが分かっており、最初に得られる極値から a 波, b 波, ..., e 波と呼ぶ。この時、それぞれの波の極値を a, b, \dots, e としたとき、時刻 t における SDPTGAI (Second Derivative of PleThysmoGram Aging Index) は下記のように定義され、この値を今回用いる特徴量 $x_1(t)$ とする。

$$x_1(t) = \frac{(b - c - d - e)}{a} \quad (2)$$

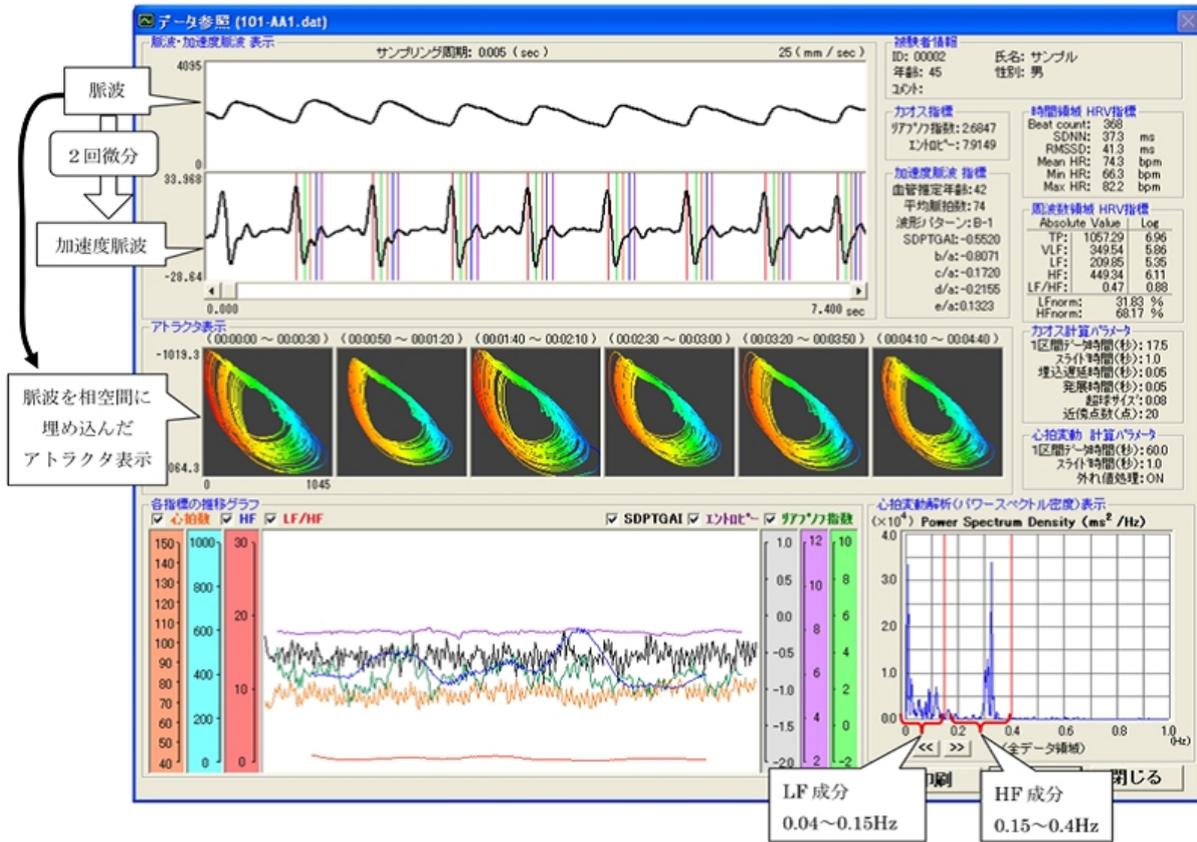


図 4 容積脈波から脈波特徴量の算出 (BACS 製品マニュアルより)。
Fig. 4 Feature extracted from plethysmogram (reference : BACS manual) .

この SDPTGA は、一般に血管の柔軟性を表す指標として用いられている脈波の特徴量である。

タイプ2: 心拍系特徴量

次に心拍系特徴量の算出について述べる。容積脈波のピーク間の間隔を PPI(peak-to-peak interval times) と呼び、この値を $x_2(t)$ とする。この時、心拍数 $x_3(t)$ は、PPI(peak-to-peak interval times) $x_2(t)$ から下記の式を用いて算出する。

$$x_3(t) = \frac{60}{x_2(t)} \quad (3)$$

タイプ3: パワースペクトル密度系特徴量

PPI $x_2(t)$ から外れ値を除去し、時間窓 $[t - ws_{fs}/2, t + ws_{fs}/2]$ (サイズは 30[sec]) でパワースペクトル密度を算出する。そして、0.04[Hz] から 0.15[Hz] までの LF 周波数帯域に属するパワースペクトル密度 $PSD_{LF}(t)$ と、0.15[Hz] から 0.40[Hz] までの HF 周波数帯域に属するパワースペクトル密度 $PSD_{HF}(t)$ を算出する。(図 4 参照) ここで、LF 周波数帯域のパワースペクトル密度 $PSD_{LF}(t)$ は、血圧変動 (メイヤー波) や自律神経の一つである興奮作用のある交感神経の活動状態を表す指標とされている [13]。また、HF 周波数帯域のパワースペクトル密度 $PSD_{HF}(t)$ は、自律神経の一つである抑制作用のある副交感神経の活動状態や呼吸変動状態を表す指標とされている。すなわち、

$PSD_{LF}(t)$ と $PSD_{HF}(t)$ との割合の変動が興奮作用と抑制作用のバランス関わっているため、これらの値を観察することで低次メンタル状態を推定できる可能性がある。ここでは、脈波特徴量として下記の $x_4(t)$, $x_5(t)$, $x_6(t)$ を算出する。

$$x_4(t) = \log \frac{PSD_{HF}(t)}{PSD_{all}(t)} \quad (4)$$

$$x_5(t) = \log \frac{PSD_{LF}(t)}{PSD_{all}(t)} \quad (5)$$

$$x_6(t) = \log \frac{PSD_{LF}(t)}{PSD_{HF}(t)} \quad (6)$$

また、MeanHR $x_7(t)$ として、時間窓 $[t - ws_{fs}/2, t + ws_{fs}/2]$ における平均心拍数を用いる。

タイプ4: カオス系特徴量

図 4 に 4 次の時間遅れのアトラクタを 2 次元射影したものを示す。このアトラクタから最大リヤプノフ係数 $x_8(t)$ を下記の通りに算出する [14]。

$$x_8(t) = \max_{d=1,2,3,4} \lambda_d \quad (7)$$

なお、ここでの時間窓は 17.5[sec] である。また、リヤプノフ係数は以下のように算出する。

$$\lambda_d = \lim_{n \rightarrow \infty} \frac{1}{n\tau} \sum_{j=1}^n \ln A_j e^j \quad (8)$$

なお、 d が時間遅れ次元、 n はアトラクタ上のデータサンプル数、 A_j はアトラクタ軌道正接ベクトルの線形演算行列、 τ は時間間隔、そして e_d^j は正接空間の基底ベクトルを表す。ここで、容積脈波が定常状態の場合、すなわちリヤプノフ係数 λ が正の場合は、アトラクタ軌道がカオスの挙動を示すが、正でない場合はアトラクタ軌道に乱れを生じることが分かる。すなわち、リヤプノフ係数の値を観察することで容積脈波の乱れ、すなわち低次メンタル状態の変化につながるようになる。

さらに、カオスアトラクタのエントロピー $x_9(t)$ を以下の式に基づき算出する。

$$x_9(t) = -\sum_{i=1}^N p_i \log p_i \quad (9)$$

なお、 p_i は位相空間における i 番目の小領域を通過するアトラクタポイントの割合を、また、 N は小領域の全アトラクタポイント数を表す。エントロピー $x_9(t)$ はカオスの乱れを表しているため、この値もまた低次メンタル状態の変動指標として有効である可能性がある。

図 ?? に耳朶ならび指先それぞれから得られた脈波特徴量 ($\log(LF/HF)$, リヤプノフ係数, エントロピー) の時系列データを示す。通常、耳朶から得られる特徴量が、通常利用される指先から取得した脈波特徴量とほとんど変わらないことが分かる。タイプ 1 から 4 までの脈波特徴量は、それぞれ観測時間 t ごとに定義される。特に、タイプ 3 (パワースペクトル密度系特徴量) とタイプ 4 (カオス系特徴量) は時間 t 前後の区間である時間窓の中で算出されるため、主観的な時間ではなく時間窓における容積脈波の情報が含まれていると解釈できる。

各脈波特徴量 $x_i(t)$ ($i = 1, \dots, 9$) とも時間解像度が異なるので、3 次スプライン内挿により特徴量間の時間解像度をサンプリング周波数 $100[Hz]$ に合わせるとともに、データの最大値最小値に基づいて規格化した 9 次元ベクトルを脈波特徴量 $\mathbf{X}_{\text{raw}}(t)$ とする。

$$\mathbf{X}_{\text{raw}}(t) = (x_1(t), \dots, x_9(t))^T \quad (10)$$

なお、脈波特徴量 $\mathbf{X}(t)$ は時系列データなので、トレンド等のノイズが重畳する可能性がある。また、低次メンタルの変動を推定するには、脈波特徴量の変動を見る必要がある。そこで、時間階差をとった $\mathbf{X}(t)$ を、以降、脈波特徴量の入力データとして用いる。

$$\mathbf{X}(t) = \mathbf{X}_{\text{raw}}(t) - \mathbf{X}_{\text{raw}}(t-1) \quad (11)$$

3. 低次メンタル状態の推定

3.1 回帰モデル

近年、ディープラーニングを用いた手法が様々な分野で提供されている、しかし、ディープラーニングを構築する

ためには、学習に用いるデータが質的にも量的にも求められるので、適用対象によっては実現が難しい場合がある。特に本論文で扱うようなユーザの反応や生体情報などのデータを、大量に収集することは困難であり、また、データの特長上、ゆらぎがあるデータ間の写像関係を構築する必要がある。従って適用する回帰モデルは、過学習を起こしにくく、また、柔軟な回帰が実現できる手法を選択する必要がある。そこで、回帰モデルの評価関数に拘束条件があるため過学習を起こしにくく、またカーネルベースのアプローチであるために柔軟な回帰が期待できるガウス過程モデルと SVR 回帰モデルを選択する。

3.1.1 ガウス過程回帰モデル

はじめに、ガウス過程回帰モデル (GPR) [15],[16] の概要について述べる。 N セットの入力ベクトルデータ $\mathbf{X}_i = (x_{i1}, \dots, x_{id})^T$ と対応している出力データ y_1, \dots, y_N の同時生起確率が多次元ガウス分布に従っている時、入出力データをつなぐ重み行列 \mathbf{w} は以下のように表される。

$$\mathbf{w} \sim \mathcal{N}(0, \lambda^2 \mathbf{I}) \quad (12)$$

ここで、推定される出力データ $\hat{\mathbf{y}} (= (\hat{y}_1, \dots, \hat{y}_N))$ は以下のように表される。

$$\hat{\mathbf{y}} \sim \mathcal{N}(0, \lambda^2 \Phi \Phi^T) \quad (13)$$

ここで、 λ^2 と Φ は、それぞれ w の分散と基底関数行列を表す。また、 $\mathbf{K} (= \lambda^2 \Phi \Phi^T)$ は、基底関数の共分散行列である。 \mathbf{K} が正定値行列になるようにカーネル関数を選べば、出力データの推定値 $\hat{\mathbf{y}}$ が得られる。GPR はカーネル法を用いたベイズ推定をベースとしているので、過学習を起こしにくい。また、GPR は回帰モデルとしてだけでなく、ディープラーニングを学習させる際のパラメータチューニングで使われるベイズ最適化にも利用されている。今回の低次メンタル状態のように出力データ $\hat{\mathbf{y}}$ のようにゆらぎがある場合、推定する各出力データごと分散も得られるので推定の確信度としても利用できるメリットがある。

3.1.2 サポートベクトル回帰モデル

次に、サポートベクトル回帰モデル (SVR) [17] の概要について述べる。二クラス問題でよく用いられるサポートベクターマシンとは異なり、SVR では評価関数 S_r は、 \mathbf{y} の次元を D とすると以下のように表される。

$$S_r = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{d=1}^D \mathbf{h}(\hat{\mathbf{y}} - \mathbf{y}) \quad (14)$$

また、評価関数 S_r の第二項が L1 なので、L1 最適化問題を解くことになるため、リッジ回帰モデルのベイズ推定を利用した GPR に比べ SVR はスパースな回帰モデルとなる。

3.2 回帰に有効な脈波特徴量の特徴選択

1 で述べた通り、適用するアプリケーションによって有

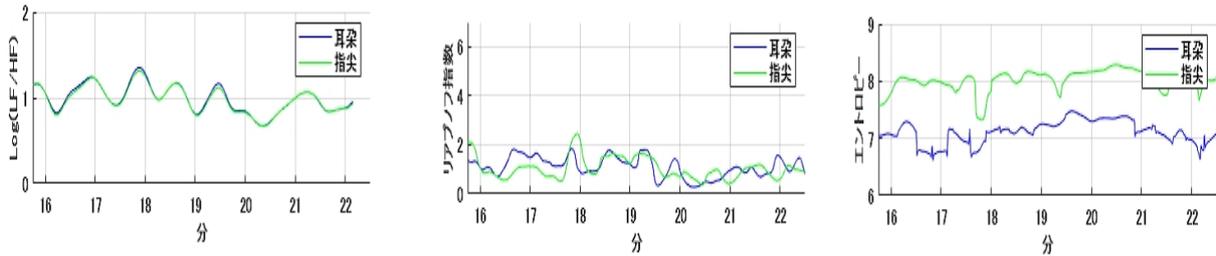


図 5 耳朶と指先のそれぞれから得られた脈波特徴量の比較.
 Fig. 5 Feature from earlobe and fingertips plethysmogram.

効な脈波特徴量がそれぞれ異なる．そこで関連度自動決定 [15],[18] という手法を用いて，説明変数に相当する入力ベクトルの各要素が回帰に寄与している程度を分析し，回帰に有効な脈波特徴量を明らかにする．関連度自動決定については以下に示すカーネル関数を用いて GPR を実施する．

$$\mathbf{K}(\mathbf{x}_n, \mathbf{x}_{n'}) = \exp\left(-\frac{1}{2} \sum_{d=1}^D \left(\frac{x_{nd} - x_{n'd}}{l_d}\right)^2\right) \quad (15)$$

ここで， \mathbf{x}_n と $\mathbf{x}_{n'}$ は，それぞれ n 番目と n' 番目の説明変数となる入力データの要素を，そして， x_{nd} は， n 番目のデータセットにおける d 番目の入力データの要素を表す．また， l_d は， d 番目の入力データの寄与度を表す指標となり，値が小さい程，回帰に対する寄与度が大きいことを意味する．この関連度自動決定 (ARD) を持ちいて得られる l_d の大きさを分析することで，低次メンタル状態の回帰に寄与度が高い特徴量を抽出する．

4. 評価実験結果

GPR と SVR をそれぞれ用いて，時間階差をとった脈波特徴量を入力データと，低次メンタル状態の変動指標と見做した主観評価量の総合点を出力データとの回帰モデルを構築する．いずれも k -hold 法による交差検定 ($k = 5$) により回帰モデルを評価した．なお，自信を持って反応があったと言える低次メンタル状態の数が被験者に依って差があったため，全ての被験者のデータを組み合わせて評価実験を行った．

4.1 GPR と SVR による回帰モデル

図 6 と図 7 は，GPR と SVR のそれぞれを用いて学習させた回帰モデルを使って検証データに適用した時の結果を示す．図 8 と図 9 は，GPR と SVR のそれぞれ回帰モデルの検証データに対する回帰係数 (推定値のズレ) を表したものである．GPR, SVR の両回帰モデルとも，実際の出力データに近い値を推定値として回帰していることが分かる．実際の出力データと推定された出力データとの回帰係数も検証データに対して約 0.98 を示し，脈波特徴量の時間階差を使って低次メンタル状態が回帰できる可能性を

示すことができた．GPR では事前確率分布を，SVR では評価関数における拘束条件をそれぞれ用いているのでデータ数がビックデータのように豊富になくとも過学習することがなく検証データでも有効な結果を示している．また，脈波特徴量や主観評価などゆらぎのあるデータであってもネールベースアプローチを用いているので，対応できると考えられる．拘束条件を組み込んだディープラーニングも提案されているが，そもそも学習データを豊富に用意する必要があり，パラメータチューニングの手間を考えると，今回のようにデータにゆらぎがあり，かつデータが豊富に用意できない場合は，GPR や SVR が有効な手段になる．

なお，今回の回帰精度は，SVR の方が GPR に比べて若干良い結果を示した．これは，SVR が L1 最適化に基づいているためスパースな回帰モデルとなり，これが結果として生体情報や感覚量のようなノイズを含むデータの回帰には適したものになったと考えられる．一方，GPR による回帰モデルでは，出力データをガウス分布の中心 (平均) として推定するだけでなく，ガウス分布の幅を表す分散，すなわち推定のゆらぎ (バラつき) の度合も分かる．例えば，推定値が実際の出力データに近いものであっても，推定時に得られる分散が大きいということは，そのデータに関しての推定のバラつきが大きい，すなわち推定精度の確信度が低いとも解釈できる．推定精度の確信度が低いのは，入力データと出力データの対応関係が質の良いものではない可能性がある．この推定時の分散を入出力データセットの対応関係の質を評価する指標として利用することが考えられる．すなわち，この指標が大きい入出力のデータセットを学習データから排除することでより精度の高い学習の実現が期待できる．

4.2 低次メンタル状態推定に有効な脈波特徴量の選択

図 10 にカーネル関数に関連を用いて GPR を実施した時の各脈波特徴量の回帰に対する寄与度 l_d の結果を示す．これより，パワースペクトル密度系特徴量とカオス系特徴量が低次メンタル状態の推定 (回帰) に寄与していることが分かる．また，加速度脈波系特徴量や心拍系特徴量は，低次メンタル状態の推定には有効でないこと分かる．前者の各特徴量は算出する際，時間窓のデータを用いているた

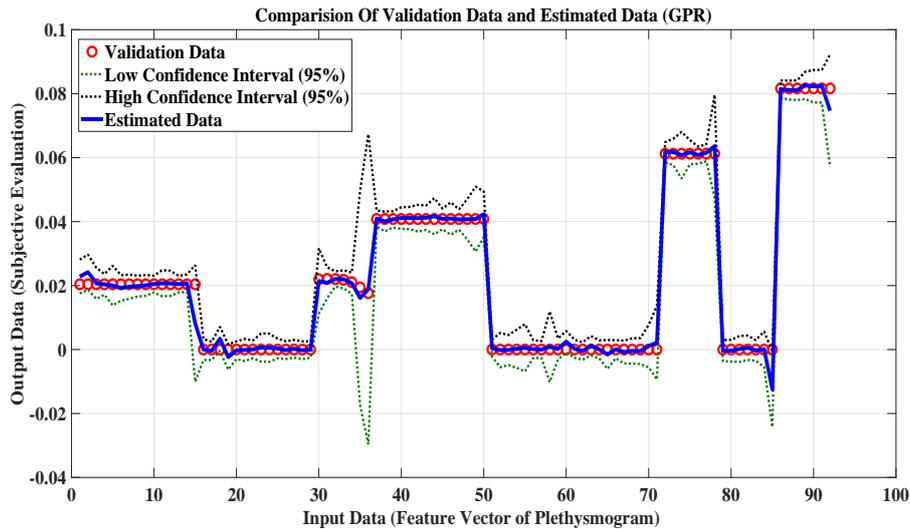


図 6 ガウス過程回帰モデル (検証データ) .
 Fig. 6 Regression by GPR(Validation Data).

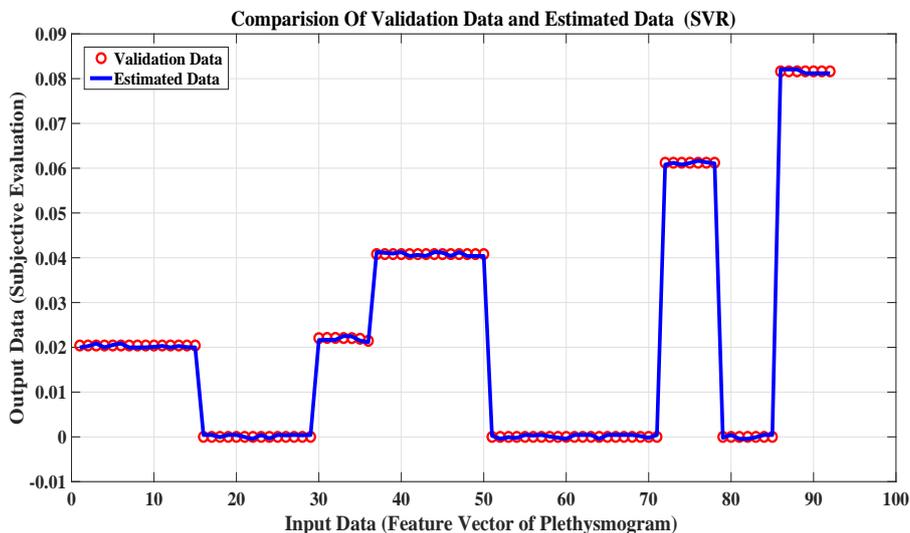


図 7 SVR 回帰モデル (検証データ) .
 Fig. 7 Regression by SVR(Validation Data).

め、脈波特徴量の特性を含んでいるのとノイズに強いために有効であると考えられる。それに対して後者の特徴量は、時間に関する二階微分や極値、もしくは波形のピークの検出など、抽出精度が求められるために、回帰には有効ではなかったと考えられる。

5. おわりに

脈波特徴量から低次メンタル状態を推定する方式として、GPR ならびに SVR のそれぞれを用いた回帰モデルを提案した。実際に 13 名の被験者に対するモバイルサービス利用時の耳差容積脈波と主観評価に基づき、提案手法の有効性を検証したところ、両回帰モデルとも検証データに対して、回帰係数が 0.98 程度の性能を得ることができた。また、ARD カーネル関数を用いた GPR により、低次メン

タル状態に有効な脈波特徴量は、パワースペクトル密度系特徴量とカオス系特徴量が低次メンタル状態であることが分かった。今後は、GPR を使った回帰モデルから得られる推定値の分散情報に基づき、より質の高い入出力のデータをセットを選定して学習させるなど提案手法の改善を図る。また、実応用の観点からは、GPR の計算処理時間の短縮化や、GPR と SVR とのハイブリッド方式などを検討する。さらに低次メンタル状態の分類や個人特性についても、さらなる分析を進める。

参考文献

- [1] John Allen. Photoplethysmography and its application in clinical physiological measurement. *Physiological measurement*, Vol. 28, pp. R1–39, 04 2007.

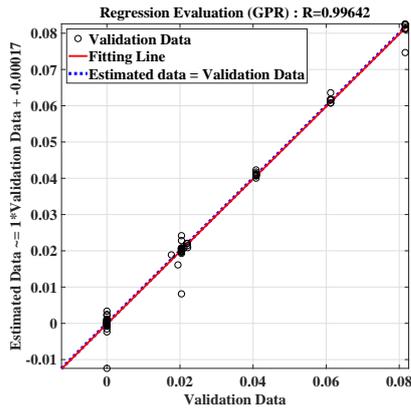


図 8 回帰係数による GPR 回帰モデルの評価。
 Fig. 8 Evaluation of Regression by GPR.

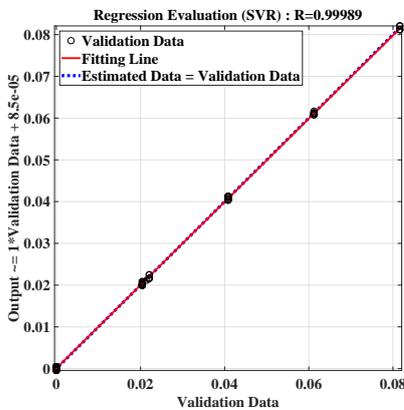


図 9 回帰係数による SVR 回帰モデルの評価。
 Fig. 9 Evaluation of Regression by SVR.

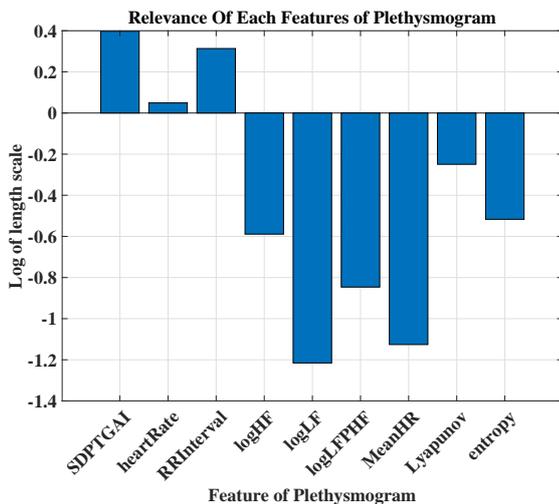


図 10 ARD カーネル関数を GPR 回帰モデルに基づく脈波特徴量選択。
 Fig. 10 Feature Selection by using ARD with the GPR.

[2] M. Oyama-Higa, T. Miao, and Y. Mizuno-Matsumoto. Analysis of dementia in aged subjects through chaos analysis of fingertip pulse waves. In *2006 IEEE International Conference on Systems, Man and Cybernetics*,

Vol. 4, pp. 2863–2867, Oct 2006.

[3] Mayumi Oyama-Higa and Tiejun Miao. Representation of a physio-psychological index through constellation graphs. In *ICNC (1)'05*, pp. 811–817, 2005.

[4] José Vicente, Pablo Laguna, Ariadna Bartra, and Raquel Bailón. Drowsiness detection using heart rate variability. *Medical & Biological Engineering & Computing*, Vol. 54, No. 6, pp. 927–937, Jun 2016.

[5] Daniel I. Loube, Teotimo Andrada, and Robin S. Howard. Accuracy of respiratory inductive plethysmography for the diagnosis of upper airway resistance syndrome. *Chest*, Vol. 115, No. 5, pp. 1333 – 1337, 1999.

[6] Ayal Romem, Anat Romem, Dafna Koldobskiy, and Schar. Diagnosis of obstructive sleep apnea using pulse oximeter derived photoplethysmographic signals. *Journal of Clinical Sleep Medicine*, Vol. 10, No. 3, pp. 285–290, 2014.

[7] K. Murata, E. Fujita, S. Kojima, S. Maeda, Y. Ogura, T. Kamei, T. Tsuji, S. Kaneko, M. Yoshizumi, and N. Suzuki. Noninvasive biological sensor system for detection of drunk driving. *IEEE Transactions on Information Technology in Biomedicine*, Vol. 15, No. 1, pp. 19–25, Jan 2011.

[8] Wilkey Wong, Mike Bartels, and Nina Chrobot. Practical eye tracking of the ecommerce website user experience. In Constantine Stephanidis and Margherita Antona, editors, *Universal Access in Human-Computer Interaction. Design for All and Accessibility Practice*, pp. 109–118, Cham, 2014. Springer International Publishing.

[9] TAKEO SUMIDA, YOITCHI ARIMITU, TAKASHI TAHARA, and HIROAKI IWANAGA. Mental conditions reflected by the chaos of pulsation in capillary vessels. *International Journal of Bifurcation and Chaos*, Vol. 10, No. 09, pp. 2245–2255, 2000.

[10] Shinji Kimura, Msaaki Fukuomoto, and Tsutomu Horikoshi. Eyeglass-based hands-free videophone. *Proceedings of the 2013 International Symposium on Wearable Computers*, pp. 117–124, 2013.

[11] 本多麻子, 正木宏明, 山崎勝男. 情動喚起刺激が自律神経系の反応特異性に及ぼす影響. *生理心理学と精神生理学*, Vol. 20, No. 1, pp. 9–17, 2002.

[12] 一般社団法人日本循環器学会 2011-2012 年度合同研究班報告. 血管機能の非侵襲的評価法に関するガイドライン. 循環器病の診断と治療に関するガイドライン.

[13] Fred Shaffer and J. P. Ginsberg. An overview of heart rate variability metrics and norms. *Frontiers in Public Health*, Vol. 5, p. 258, 2017.

[14] M. Sano and Y. Sawada. Measurement of the lyapunov spectrum from a chaotic time series. *Phys. Rev. Lett.*, Vol. 55, pp. 1082–1085, Sep 1985.

[15] 大羽 成征持橋 大地. *ガウス過程と機械学習*. 講談社, 2019.

[16] By Carl Edward Rasmussen and Christopher K. I. Williams. *Gaussian Processes for Machine Learning*. The MIT Press, 2006.

[17] Alex J. Smola and Bernhard Schölkopf. A tutorial on support vector regression. *Statistics and Computing*, Vol. 14, No. 3, pp. 199–222, August 2004.

[18] David P. Wipf and Srikantan S. Nagarajan. A new view of automatic relevance determination. In J. C. Platt, D. Koller, Y. Singer, and S. T. Roweis, editors, *Advances in Neural Information Processing Systems 20*, pp. 1625–1632. Curran Associates, Inc., 2008.