

# 心電と脈波の時間差を用いた ウェアラブル端末装着位置推定手法

吉田 航輝<sup>1</sup> 村尾 和哉<sup>1</sup>

**概要:** 種々のセンサを搭載したウェアラブルデバイスの普及により, 時間や場所を問わず人間の行動や状況をセンシングしてデータを収集できるようになった. 任意の身体部位に装着できるセンサを1箇所装着すると, 装着位置によって処理モデルを切り替える必要がある. また, 同一形状のセンサを複数装着する場合, センサを区別するために身体部位を動かしてデータの変化を見る作業が必要である. そのため, ウェアラブルデバイスをさまざまな身体部位に自由に装着する環境において, デバイスの装着部位を動的に推定する手法が必要である. ウェアラブルデバイスの装着部位を推定する手法として, ウェアラブルデバイスの加速度センサや角速度センサから得られた時系列データを用いた手法が提案されている. これらの研究では歩行動作などの特定行動をしなければ装着位置の推定ができないという問題点がある. 本研究では装着者に特定の行動を強いることなく, ウェアラブルデバイスの装着位置を推定する手法を提案する. 提案手法は心電センサ (ECG) で得られた心拍と脈拍センサで得られた脈波との時間差を推定し, 推定された時間差からデバイスの装着位置を推定する. 脈拍センサはウェアラブルデバイスに搭載されていると仮定している. 男性5名から2分間の心電と脈波のデータを身体部位15箇所から収集して, 提案手法の評価実験を行った結果, 平均F値は0.805となった. 特に, 被験者がデバイスを装着してから約20秒間のデータを用いることで左耳と右手指は0.9を超えるF値が得られた.

## 1. はじめに

種々のセンサを搭載したウェアラブルデバイスの普及により, 時間や場所を問わず人間の行動や状況をセンシングして加速度や角速度, 光, 脈波, 位置, 電波状況, 筋電図 (EMG) [1], 心電図 (ECG) [2], 電気皮膚反応 (GSR) [3] などのデータを収集し, ネットワーク上に蓄積し, 高性能な計算機で処理できるようになった. 人間の行動をセンシングして得られるデータは, 生活パターンを自動抽出して運動不足や過労を警告する健康管理システム [3], 組立作業において動作から次の作業を予測して手順書や必要機材を提示する作業支援システム [4], 病院外における患者の服薬や血糖値計測の時刻を医師が正確に把握する医療支援システム, タックルやスプリントの回数及び強度を取得するスポーツ支援システム<sup>\*1</sup>, 観客の動作によって演出が変化するエンタテインメント, 歩容や機器の操作にもとづく本人認証, 動作で機器を操作する入力インタフェースやゲーム [5], などの分野において, これまでは手作業や人間の勘, 人海戦術で行われてきた作業, 実現困難であった高度な作業の支援への応用が期待されている.

現在市販されているウェアラブルデバイスは時計型, 腕輪型, 眼鏡型, ベルト型, 衣服型などさまざまな形状であり, それらのデバイスを装着する身体部位は限定される. 一方で, インスタントタトゥ型 [6] や絆創膏型 [7], 汎用センサ [8] など任意の身体部位に装着可能なウェアラブルデバイスも存在する. ウェアラブルデバイスが身体の任意の部分に取り付けられる場合, 取り付けられた位置によってアプリケーションが処理を変更するために, 装着位置を識別する必要がある. 例えば, 人間行動認識システム [9] は, 学習データドメインがテストデータドメインと異なる場合に認識精度が大幅に低下するため, 装着位置によって機械学習アルゴリズムのモデルを変更する必要がある. つまり, 足のジェスチャを学習したモデルを使用して手のジェスチャの認識しようとするとう誤認識が発生する. あるいは, ウェアラブルデバイスの装着位置に応じてディスプレイやLED, 音, 振動などの出力デバイスの情報提示方法を変えることができる.

近年, 身体上を動くことができるロボットが提案されている. Rovables [10] は磁気ホイールで衣服の上を移動する. Skinbot [11] は2つの吸盤で皮膚上を動くロボットである. 吸盤の内側に挿入された電極から心電などの生体電位を測定できる. これらのウェアラブルロボットには, 自己位置

<sup>1</sup> 立命館大学 情報理工学研究所

<sup>\*1</sup> CATAPULT, <https://www.catapultsports.com/>

推定が必要であるが、Skinbot は自己位置を推定することはできない。Rovables は、自己位置の推定に慣性航法を使用している。慣性航法は位置推定アルゴリズムのひとつで、現在位置は前の位置からの相対的な移動によって決定されるため、初期位置が必要となる。

身体全体の動きを捉えるために複数のウェアラブルデバイスを使用するシステムにおいてもデバイスの装着位置を推定することは重要である。複数の同じウェアラブルデバイスを人間行動認識のために使用することを想定すると、ウェアラブルデバイスは Bluetooth や USB ケーブルを介して PC に接続されて、COM ポートが各ウェアラブルデバイスに割り当てられる。PC 上で動作するシステムは COM ポートによってウェアラブルデバイスを識別するが、そのままではシステムはデバイスが接続されているポートを識別することはできない。ユーザは通常、身体部位を個別に動かしてその波形を見てから、身体部位に関連付けられている COM ポートを確認する。センサにシールが貼ってあり装着する身体部位がウェアラブルデバイスごとに決まっていたとしても、COM ポートは接続時に変わることがよくあるため、デバイスの装着位置推定は必要である。

ウェアラブルデバイスの装着部位を推定する研究は 2 つに分類され、1 つは同じ身体部位における変位の検出と補正をする研究、もう 1 つは装着位置を推定する研究である。前者の研究として Hamidreza ら [12] は、センサ値を補正することで単一の認識モデルで人間の行動を認識することを可能にしている。従来の手法では、数 cm 程度の変位を補正することはできるが、大きな変位またはセンサが関節を跨いで異なる肢部に取り付けられる場合は補正が困難であり、結果として性能が低下する。後者の研究として、事前に定義している身体部位の中からデバイスの位置を推定する研究 [13], [14] がある。しかし、これらの研究では歩行動作などの特定行動をしなければ装着位置を推定できないという問題点がある。

本研究ではウェアラブルデバイスで取得可能な生体信号である心電と脈波を利用し、特定の行動を装着者に行わせることなくウェアラブルデバイスの装着部位を推定する手法を提案する。心臓が血液を体内に送り出すとき、心臓右心房付近にある洞結節と呼ばれる部分が電気刺激によって心臓の収縮を指令する。心電センサはこの電気刺激の電位を取得する。現在では 500 円サイズの小型の心電センサや衣服型の心電センサが発売されており、心電を解析することで心拍数や精神状態を取得できるため、将来的には心電の常時計測が一般的となると予想している。一方、左心室から大動脈を経て全身に送出された血液は動脈を通り、毛細血管へと到達する。脈波センサは、血流量の変化を取得する。心臓からの距離に応じて脈波が到達する時間は身体の部位によって異なることに着目し、提案手法は心電センサで計測された心拍と脈波センサで計測された脈波の時間

差を算出し、それら時間差を用いてウェアラブルデバイスの装着位置を推定する。

以降、2 節では関連研究を紹介する。3 節では提案手法を説明し、4 節では提案手法の評価実験を行い、5 節では結果について議論し、最後に 6 節で本研究をまとめる。

## 2. 関連研究

本節では、センサ位置に関する調査研究、ウェアラブルデバイスやスマートフォンの装着位置推定、センサの変位とデータの補正、心電と脈波の時間差に関する研究を紹介する。

### 2.1 行動認識におけるセンサ位置に関する評価研究

村尾ら [15] は、認識精度とセンサの装着性の両方を考慮してセンサ配置をスコア付けする評価関数を提案している。20 個のセンサをユーザの身体に装着し、有酸素運動、ウェイトトレーニング、ヨガなどの 30 種類の運動を行い装着位置を推定した。結果、86%の精度で装着者がストレスを感じることなく位置を推定することができている。Louis ら [16] は加速度センサを耳、胸、腕、手首、腰、膝、足首の 7 箇所に装着してもらい、各センサの装着位置ごとの精度の違いを調べた。結果、腕または耳に取り付けるのが最も精度が高く出ることを示した。

### 2.2 ウェアラブルデバイスの装着位置を推定する研究

誤った身体部位の分類モデルを使用すると分類性能が低下することを報告している研究が存在する。Apiwat ら [17] は、10 人の被験者のシャツポケット、ズボンポケット、腰部の 3 箇所に加速度センサをつけてもらい、6 種類の異なる行動を行ってデータを収集した。結果、動作判定には正しい装着位置のモデルが必要であることを示した。

ウェアラブルデバイスの装着位置を推定する研究として、Vahdatpour ら [13] は加速度データを用いてウェアラブルセンサの装着位置を推定している。25 人の被験者の頭部、胸部、両上腕、両前腕、腰部、両大腿部、両脛部の計 10 箇所に加速度センサを装着してもらい、歩行行動などの日常行動下で加速度データを収集した。収集したデータから Support Vector Machine (SVM) を用いて装着部位を推定した。結果、平均 84%の精度で装着部位を推定している。Timo ら [18] は 15 人の被験者の頭部、胸部、左上腕、左手首、腰部、服の前ポケット、左足首の計 7 箇所に加速度センサを装着してもらい、歩行や走るなどの行動の加速度データを収集した。収集したデータから Random Forest を用いて装着部位を推定した。結果、平均 89%の精度で装着部位を推定している。Kunze ら [19] は 6 人の被験者に右手首、右目の横、ズボンの左ポケット、左胸のポケットに加速度センサを装着してもらい、歩行動作のデータを収集した。収集したデータから C4.5 分類木を用いて装着部位

を推定した結果、平均 94%の精度で推定している。

高田ら [14] は加速度データと角速度データを用いてウェアラブルデバイスの装着位置を推定している。10 人の被験者の頭部、胸部、左手首、右手首、腰部、服の前ポケット、服の後ろポケット、左足首、右足首の計 10 箇所にウェアラブルデバイスを装着してもらい、歩行行動などの日常行動下で加速度・角速度データを収集した。収集したデータから Random Forest を用いて装着部位を推定した。結果、最大の推定精度が 98.2%、10 人における推定精度の平均が 90.0%となっている。渡辺ら [20] は被験者に腰回りの計 8 箇所にウェアラブルデバイスを装着してもらい、歩く、走る、階段を上る、階段を下りるの 4 つの行動を行い、加速度・角速度データを収集した。収集データのうち 3 セットを学習用、1 セットをテスト用として学習を行った。学習データとテストデータに同一行動のみを用いた場合、最大 96.4%の精度でセンサの装着位置を推定している。また、学習データとテストデータに 4 種類の行動すべてを用いた場合、最大 84.6%の精度でセンサの装着位置を推定している。

### 2.3 スマートフォンの格納位置を推定する研究

スマートフォンなどのモバイルデバイスの格納位置を推定する研究も存在する。Coskun ら [21] は加速度データを用いて携帯端末の格納位置を推定している。15 人の被験者に手、バックパック、服のポケットの計 3 箇所に携帯端末を所持してもらい、歩行や走るなどの日常行動下で加速度データを収集した。収集したデータから Random Forest を用いて格納位置を推定した。結果、平均 77.34%の精度で格納位置を推定している。また、加速度データと角速度データを併用して携帯端末の格納位置を推定すると精度は平均 85%に向上している。Martin ら [22] は加速度データや角速度データなどを用いて携帯端末の格納位置を推定している。結果、最大 92.94%の精度で推定している。藤波ら [23] は加速度データを用いて携帯端末の格納位置を推定している。ズボンの前ポケット、ズボンの後ろポケット、ジャケットのポケット、胸ポケット、首かけストラップの 5 つの収納位置を歩行中に推定している。結果、72.3%の精度で推定している。

倉沢ら [24] は 3 軸加速度センサのデータを用いてウェアラブルデバイスの装着位置を推定している。この研究はユーザの姿勢を推定するためにウェアラブルデバイスの装着位置を推定しており、鞆の中、ズボンのポケット、上着のポケットの 3 か所に対して、装着位置を 98.1%の精度で推定できている。Park ら [25] は加速度データを用いて携帯端末の格納位置を推定している。9 人の被験者に手、耳、バックパック、服のポケットの計 4 箇所に携帯端末を所持してもらい、歩行下で加速度データを収集した。結果、平均 94%の精度で推定している。

これらの研究では、装着位置推定に歩行などの特定の動作を行っている区間の特徴量を用いている。具体的には装着部位がラベルとして付与された動作データを用いてモデルを作成し、未知の装着部位のデータに対して作成したモデルを用いて装着位置を推定している。そのため、歩行などの特定の動作を行わなければならない制約がある。本研究ではウェアラブルデバイス装着者自身の生体信号である心電と脈波を利用することで、歩行行動や静止行動などの特定の行動に関係なく装着位置を推定し、装着者がウェアラブルデバイスを装着するだけで装着位置を推定できる。

既存研究の多くは加速度センサや角速度センサのデータを用いてセンサの装着位置を推定しているが、本研究のように心電と脈波を用いる手法は筆者らの知る限り存在しない。

### 2.4 センサの変位と補正に関する研究

Hamidreza ら [12] は被験者 1 名の右下腕に位置をずらして 6 箇所に加速度センサを装着してもらいデータを収集した。センサデータの分布から装着位置を推定した結果、平均 84%の精度で推定している。この研究では小さな変位は補正することができるが、大きな変位またはセンサが関節を跨いで異なる部位に取り付けられる場合は補正が困難であり、結果として行動認識精度が低下することが示されている。

### 2.5 心電と脈波の時間差に関する研究

心電と脈波の時間差を用いた研究はこれまでに数多く行われている。心電と脈波の時間差から血圧値の推測や血管年齢の推定などを行う手法 [26] がある。また、心電のピーク時刻を脈波の時間差から推定する Robert らの研究 [27] がある。Robert らは脈波センサしか装着できない環境を想定し、脈波センサのデータを用いて脈波のピーク値間の時間差を計算し、その結果を用いて心電のピーク時刻を推定している。立位では 14.3 ミリ秒、座位では 9.43 ミリ秒の平均誤差で心電のピークを推定している。

このように、心電のピーク時間と脈波のピーク時間を利用した研究はこれまでに行われているが、いずれも既知の部位間の計測値から血圧などの生体情報を推定するものであり、本研究のようにデバイスが装着された部位を推定する研究は筆者らの知る限り行われていない。

## 3. 提案手法

本節では、提案手法の処理について述べる。提案手法では、図 1 に示すように心電と脈波の計測、心電と脈波のピーク検出、ピークの時間差計算、装着位置推定、の 4 つの処理から構成される。以降の各節でこれらの処理を詳細に説明する。




図 1 提案手法の流れ




図 2 脈波のピーク検出例

### 3.1 心電と脈波の計測

ユーザは胸部に小型の心電計を装着し、心電を常時計測すると想定する。ウェアラブルデバイスは脈波計を搭載しており、装着部位での脈波を計測する。また、ウェアラブルデバイスは任意のあらかじめ決められた候補の身体部位に装着すると想定する。提案手法はリアルタイムで装着位置判定を行う。現在時刻までに得られた一定区間のデータからデバイス装着位置推定を行う。例えば、10 秒間のデータが得られれば、10 秒間のデータに含まれる心電と脈波のピークをすべて検出して、それらの時間差を計算し、得られた複数個の時間差から最終的な装着位置推定結果を出力する。したがって、より長い区間のデータが与えられれば、多くの時間差を使用できるためより正確な装着位置の推定を行うことができる。

### 3.2 心電と脈波のピーク検出

取得した心電と脈波に現れるピークを検出する。センサデータは多くの場合、アナログデジタル変換器 (ADC) に起因するノイズを含んでいる。そのため、11 サンプル ( $\approx 11$  [msec]) の長さのウィンドウの移動平均フィルタ  $\sum_{i=t-5}^{t+5} f(i)$  を用いる。なお、 $f(t)$  は時刻  $t$  におけるセンサの生データである。移動平均フィルタ後の時刻  $t$  における心電を  $x_h(t)$ 、時刻  $t$  における脈波を  $x_p(t)$  と表記する。

心電データ  $x_h(t)$  ( $0 \leq t \leq T$ ) のピークを以下に従って検出する。

- (1)  $x_h(t) > T_h$  かつ、 $(x_h(t-1) < x_h(t)) \cap (x_h(t) \geq x_h(t+1))$  を満たすすべての凸ピークを探索する。凸ピーク発見後に同値が続く、すなわちピークの凸部が平坦である場合は平坦な区間の中間点をピークとする。
- (2) 閾値  $T_h = \max(x_h) - \alpha \cdot (\max(x_h) - \frac{1}{T} \sum_{t=0}^T x_h)$  以下のピークを削除する。ただし、 $\alpha$  は収集したデータから経験的に決められた係数であり、0.3 とした。
- (3) 発生時刻が近いピークを統合する。具体的には最も高いピークから順にピークの前後 0.15 秒間に他のピークがある場合はそれらを削除する。これは人間の心拍数の最大値に近い値 200bpm において、ピーク間隔が 0.3 秒であるため、通常は真のピークは 0.3 秒の間に 2 つ以上検出されることがないためである。

この処理によって心電のピーク (一般的に R 波と呼ばれる部

分) が検出される。脈波のピークも同様にして検出する。ただし、脈波はセンサと皮膚の接触状態によってピークが現れにくい場合があるため、 $250 \leq \max(x_p) - \frac{1}{T} \sum_{t=0}^T x_p \leq 450$  の場合は閾値  $T_p = \frac{1}{T} \sum_{t=0}^T x_p$  とし、それ以外の場合は (2) において  $\alpha = 0.5$  とした。

図 2 に脈波のピーク検出例を示す。図 2 中の  $\circ$  はピーク部を示している。

### 3.3 ピークの時間差計算

心電と脈波のピークの時間差を計算する。心臓から送出された血液は数十ミリ秒遅れて各身体部位において脈波として検出される。提案手法は心電のピークを基準としてそれに対応する脈波のピークを検出する。これは、脈波は脈波センサと皮膚の接触状態によって本来の脈波ではない部分にもピークが現れることがあり、心電のピークは脈波のピークより安定して検出されるためである。

時刻  $t = 0$  から開始し、心電のピークを発見すると、その心電のピークに対応する脈波のピークを検出して、時間差を計算する。この作業を  $t = T$  まで行い、すべてのピーク時間差を取得する。具体的には  $n$  番目の心電のピークの時刻を  $t = T_h[n]$  とすると、 $T_h[n] + 0.25[\text{sec}] \sim T_h[n] + 0.45[\text{sec}]$  の区間に存在する脈波のピークを探す。この区間を設定した理由は、心電と脈波の時間差がおおよそ 0.25 秒から 0.45 秒の間になるためである。これによって、脈波によるものではないピークを除外して適切な時間差を計算する。

そして、求めた脈波ピークの時刻を  $T_p[n]$  とすると、時間差  $d[n]$  は

$$d[n] = T_p[n] - T_h[n] \quad (1)$$

となる。区間内に脈波のピークが複数存在する場合は、最大値のピークを採用する。また、区間内に脈波のピークがない場合は  $n$  番目の心電のピークについては時間差を計算しない。

図 3 に左足指と右手指における心電と脈波の波形とピークを示す。図 3 に示すように、心電のピークと脈波のピークの間をピークの時間差と定義している。時間差計算により、複数の時間差データが収集される。例えば、心拍数 80[bpm] において 30 秒間の心電と脈波が得られたとすると、データに 40 個のピークがあるため、理想的には 40 サンプルの時間差が収集される。また、図 3 に示すように、

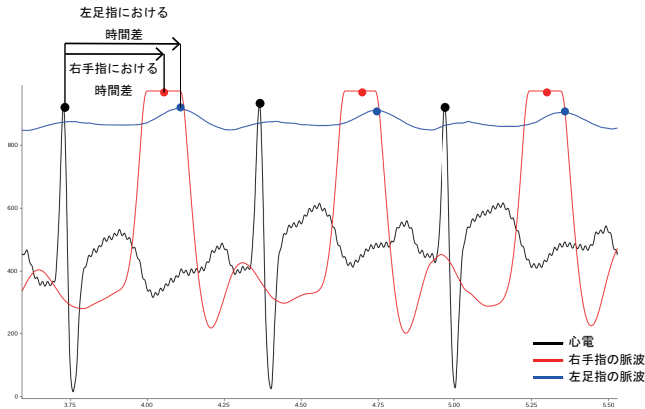


図 3 心電と脈波のピーク間の時間差

身体部位で脈波のピークがずれていることがわかる。このピークのずれを用いて装着位置の推定を行う。

### 3.4 装着位置推定

あらかじめ各身体部位で収集した時間差の集合（以下、学習データ）と未知の位置で得られた時間差の集合（以下、テストデータ）との距離を計算する。距離計算のために、提案手法では Kullback-Leibler (KL) divergence [28] を使用する。KL divergence は 2 つの確率分布の差を示す尺度である。KL divergence が 0 であることは 2 つの分布が同一であることを示している。

図 4 に KL divergence を用いて装着位置を推定するまでの流れを示す。KL divergence を計算するために、各身体部位ごとの確率分布が必要である。提案手法では、0.01 秒幅のビンで 0.25 秒から 0.45 秒までの範囲のヒストグラムを各位置のデータセットから作成する。学習データとテストデータの時間差のヒストグラムをそれぞれ  $P$  と  $Q$  とする。 $P$  と  $Q$  の間の KL divergence は以下の式で求められる。

$$d_{KL}(P||Q) = \sum_{i=1}^{20} P(i) \log \frac{P(i)}{Q(i)} \quad (2)$$

なお、 $P_i$  と  $Q_i$  は、それぞれヒストグラム  $P$  と  $Q$  の  $i$  番目のビンの度数となる。この計算において、ビンの度数が 0 であると、 $P_i$  または  $Q_i$  が 0 になり KL divergence が計算できず、 $\log 0$  となるエラーや 0 除算エラーが発生する。この問題を避けるために、一般的な対処法としてビンの度数が 0 のときは非常に小さい値である 0.001 とする。テストデータと各身体部位の訓練データセットとの間の KL divergence が計算する。  $\arg \min_{y \in \mathbb{Y}} d_{KL}(P_y||Q)$  となるような身体部位が装着位置と推定する。なお、 $\mathbb{Y}$  はウェアラブルデバイスが取り付けられている身体部位である。

## 4. 評価

本節では、提案手法の端末装着位置推定精度を評価するための実験について述べる。

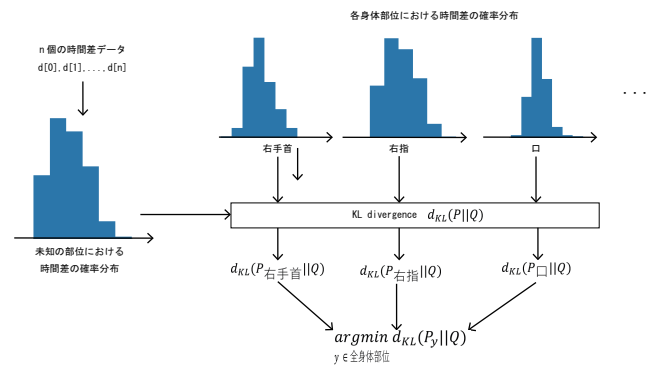


図 4 時間差を計算してから位置推定するまでの流れ

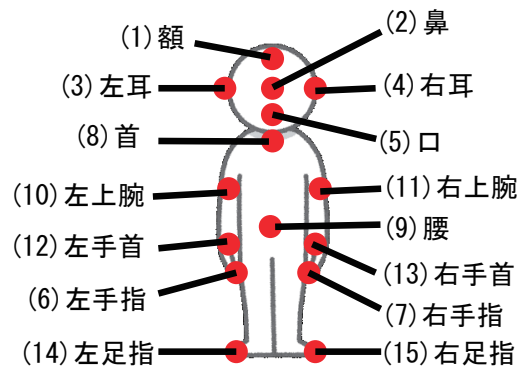


図 5 評価実験で対象とした 15 箇所の部位

### 4.1 実験環境

被験者 5 名 (A~E, 全員男性, 平均年齢 22.8 歳) の 15 箇所の身体部位に脈波センサを装着して脈波データを採取した。また、3 個の電極からなる心電センサを心臓の近くに装着して心電データを採取した。心電および脈波は各身体部位ごとに 1 分間のデータを 2 回収集した。合計で、1 分  $\times$  2 回  $\times$  15 部位  $\times$  5 名 = 150 分のデータを収集した。被験者は服を着たまま立った状態でデータを収集した。対象とした 15 箇所の部位は図 5 の赤丸の示すとおり (1) 額, (2) 鼻, (3) 左耳, (4) 右耳, (5) 口, (6) 左手指, (7) 右手指, (8) 首, (9) 腰, (10) 左上腕, (11) 右上腕, (12) 左手首, (13) 右手首, (14) 左足指, (15) 右足指である。被験者 A, B, C, D, E の実験中の平均心拍数はそれぞれ 84, 97, 98, 80, 81[bpm] であった。

心電センサとして OLIMEX 社製 SHIELD-EKG-EMG\*2, 脈波センサとして pulsesensor.com 製の脈波センサ\*3 を使用し、Arduino UNO を介して PC でデータを記録した。サンプリング周波数は約 700Hz であった。

心電と脈波の計測, 心電と脈波のピーク検出, ピークの時間差計算, および装着位置推定は Python で実装されたプログラムでオフラインで実施した。

\*2 <https://www.olimex.com/Products/Duino/Shields/SHIELD-EKG-EMG/open-source-hardware>

\*3 <https://pulsesensor.com/>

## 4.2 実験手順

脈波伝播速度 (PWV: Pulse Wave Velocity) [26] と血管の硬さ、血管壁の厚さ、血管の半径および増分弾性係数との間には関係があり、これら血管ごとに異なるため、評価はユーザ本人のデータを学習するユーザ依存とした。また、PWV は加齢とともに血管の弾力性が低下するため速くなることが知られており、ある人のモデルを他人に直接適用することはできない。提案システムの汎用性については 5 節で述べる。

データを収集後、各身体部位ごとに 100 組以上のピークを検出して時間差データを得た。この時間差データから無作為に 100 個選択し、5 個を 1 セットとして 20 セットを作成した。このうち、14 セットを学習データ、6 セットをテストデータとした。入力するデータの長さの影響を調べるために、テストデータのセット数は 1 セットから 6 セットまで変更させた。20 セットから 14 セットの学習データセットを選択する組合せおよび、6 セットから 1 セット～6 セットのテストデータを選択する組合せはクロスバリデーションのように全組合せで評価した。

## 4.3 結果と考察

### 4.3.1 ピークの時間差

被験者 5 名の各身体部位の心電と脈波のピークの時間差の平均と標準偏差を図 6 に示す。図 6 の横軸の数字は図 5 に示すのデバイスの装着位置の数字に対応している。○は評価に使用した 100 サンプルの時間差の平均値であり、上下に伸びているエラーバーは 100 サンプルの時間差の標準偏差を示している。

図 6 より、いくつかの身体部位は似た時間差となっているため、正しく装着位置が推定できないことがわかる。例えば、被験者 A の (6) 左手指、(12) 左手首、(14) 左足指では平均の時間差はそれぞれ 292[msec]、258[msec]、351[msec] である。時間差の大きさは心臓からの距離に関係していることがわかる。また、被験者 A の (12) 左手首と (13) 右手首では平均の時間差がそれぞれ 258[msec] および 306[msec] であった。この結果より、左右対称な身体部位でも脈波の到達時間に差があることがわかった。この要因は心臓の位置にあると考えられる。心臓の位置は身体を中心から外れているため、各身体部位への血管の距離が異なる。したがって、脈波の到達時間に差ができたと考えられる。

### 4.3.2 装着位置の推定精度

テストデータが 30 個のときの装着位置推定結果の混同行列を図 7 に示す。各セルは入力と出力の数を示し、左上から右下の対角線のセルが正しく推定できた数である。結果より、(1) 額、(3) 左耳、(6) 左手指、(7) 右手指の再現率は 0.9 以上となった。15 箇所の身体部位で分類することを考慮するとこれらは高い値といえる。この結果が得られた要因は時間差の平均値が異なったことと時間差の標準偏

差が小さいことであると考えられる。図 8 に各身体部位における被験者 5 人の標準偏差の平均を示す。図 8 より、(1) 額から (7) 右手指までの身体部位は標準偏差が小さい。図 6 より、被験者 A の (4) 右耳と (5) 口、被験者 D の (2) 鼻と (4) 右耳のように、(2) 鼻と (4) 右耳と (5) 口では平均の時間差が近くなりやすいことがわかった。また、(1) 額、(3) 左耳、(6) 左手指では標準偏差が小さく、平均の時間差も異なっていたため、他の身体部位と区別できるヒストグラムが生成されたことで装着位置の推定が正しく行われたと考えられる。

一方、(9) 腰、(10) 左上腕、(11) 右上腕における位置推定の精度が低い。図 7 の混同行列を見ると、腰は (10) 左上腕や (11) 右上腕と誤認識していることがわかった。この要因は心臓から上腕までの距離が似ているためであると考えられる。実際に、図 6 を見ると、被験者 A、C、E における (9) 腰、(10) 左上腕、(11) 右上腕の時間差は似ていることがわかる。さらに、被験者 C、D では (11) 右上腕と (12) 左手首の時間差も似ていることがわかる。これらのことより、心臓からの距離が近い身体部位では時間差が似てしまうため、正しく装着位置の推定ができないことが考えられる。この問題の解決策は 5 節で述べる。

### 4.3.3 入力データの長さによる精度の影響

4.3.1 節と 4.3.2 節の結果はテストデータが 6 セット、時間差データが 30 個のときのものである。心拍数が 90bpm とすると、時間差データが 30 個得られるまで 20 秒待つ必要がある。そのため、本節では入力データである時間差データの個数を変更させ、位置推定の精度の変化を評価する。

表 1 にテストデータの個数を 5、10、15、20、25、30 に変化させたときの各身体部位における平均の F 値を示す。テストデータ 30 個のときは 4.3.1 節と 4.3.2 節の結果と同じである。表 1 より、テストデータ数が増えると F 値も向上することがわかった。時間差データ 10 個のとき、15 箇所の身体部位で平均 65% で推定できる。これは約 6 秒間のデータでの精度であり、デバイスを装着している間にこの精度で位置を推定できることを意味する。また、身体部位の候補が限られていれば、位置推定する部位が少なくなり、精度が向上すると考えられる。さらに、時間差データ 30 個までテストデータを増やしても F 値は収束していないことがわかった。したがって、テストデータの個数を増やせば精度が向上すると考えられる。しかし、デバイスを装着してから位置推定が行われるまでの時間が長くなるため、デバイスの装着者の待機時間が増える。時間差データ 30 個の約 20 秒が適当な長さであると考えられる。

## 5. 議論

本節では、提案手法において解決できていない問題点を述べる。

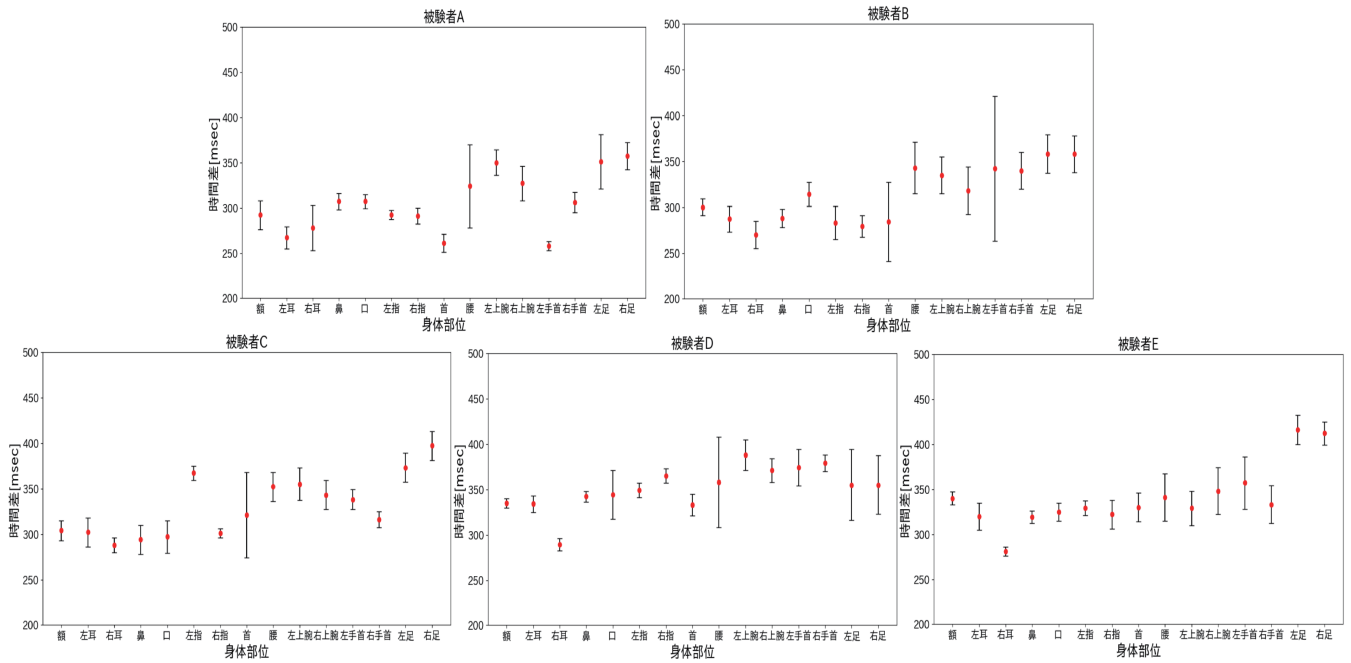


図 6 5名の被験者の各身体部位における心電と脈波のピーク時間差の平均と標準偏差

予測 正解	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)	再現率
(1)額	9042	663	39	18	90	0	115	0	0	0	1	0	32	0	0	0.904
(2)左耳	657	7748	165	289	281	178	37	483	1	161	0	0	0	0	0	0.775
(3)右耳	22	127	9469	190	0	63	11	112	6	0	0	0	0	0	0	0.947
(4)鼻	10	429	307	8317	465	67	95	0	0	0	0	0	310	0	0	0.832
(5)口	51	314	0	464	7641	308	0	366	1	12	177	0	647	0	19	0.764
(6)左手指	1	303	20	66	292	8964	181	29	0	0	0	0	1	142	1	0.896
(7)右手指	104	61	30	83	0	227	9197	15	2	71	74	6	0	2	128	0.92
(8)首	0	437	209	1	166	21	6	8128	66	381	5	262	318	0	0	0.813
(9)腰	9	0	13	0	5	0	0	58	7267	1180	1027	36	275	125	5	0.727
(10)左上腕	0	50	0	2	10	0	20	435	1167	6661	43	11	1436	5	160	0.666
(11)右上腕	0	0	0	0	96	0	17	5	1063	59	7407	1232	55	51	15	0.741
(12)左手首	0	1	0	0	0	0	7	304	35	7	1854	7761	14	6	11	0.776
(13)右手首	26	0	0	285	481	0	0	406	216	948	148	19	7466	5	0	0.747
(14)左足指	0	0	0	0	0	93	1	0	86	4	94	13	9	7984	1716	0.798
(15)右足指	0	0	0	0	11	0	57	0	5	317	61	18	0	1877	7654	0.765
適合率	0.911	0.765	0.924	0.856	0.801	0.904	0.944	0.786	0.733	0.68	0.68	0.829	0.707	0.783	0.788	

図 7 テストデータ 30 個のときの装着位置推定結果の混同行列




図 8 各身体部位における被験者ごとの時間差の標準偏差の平均

### 5.1 時間差が似ている装着位置の推定

4 節の評価結果より、脈波の到達時間が類似している身体部位がいくつかあり、それらの身体部位は互いに誤認識されていた。ここで、評価実験に用いたデータは被験者に立った状態を維持してもらっていた。そのため、今後は各

身体部位で心電と脈波の時間差が発生するような姿勢をとることで、脈波到達時間が類似している部位の推定精度を改善することを試みる。特に、腰、上腕、手首は誤認識が多かったため、時間差に違いが出るような姿勢を提案する必要がある。例えば、どちらかの腕を上げる、腕を横にする、腕を縛るなどが考えられる。また、現在の提案手法では脈波の到達時間のみ用いているが、皮膚の厚さによって脈波の変化が異なるため、脈波の振幅や脈波形状も考慮に入れると精度が上がる可能性がある。

### 5.2 ユーザの依存性

4 節の評価実験はユーザ依存で行った。すなわち、学習データとテストデータは同一人物のデータを用いた。ここで、生体力学では Moens-Korteweg の式 [29] と呼ばれる PWV と動脈壁の増分弾性係数および伸張性との関係をモ

表 1 テストデータ数が増えたときの各身体部位における装着位置推定の F 値

身体部位	テストデータの数 (個)					
	5	10	15	20	25	30
(1) 額	0.616	0.758	0.824	0.864	0.901	0.908
(2) 鼻	0.406	0.536	0.622	0.680	0.738	0.770
(3) 左耳	0.753	0.826	0.867	0.893	0.916	0.935
(4) 右耳	0.555	0.680	0.750	0.783	0.820	0.844
(5) 口	0.506	0.626	0.695	0.739	0.765	0.782
(6) 左手指	0.621	0.744	0.800	0.848	0.875	0.900
(7) 右手指	0.631	0.773	0.840	0.884	0.918	0.932
(8) 首	0.493	0.621	0.687	0.733	0.777	0.799
(9) 腰	0.441	0.574	0.637	0.675	0.710	0.730
(10) 左上腕	0.458	0.549	0.594	0.623	0.650	0.673
(11) 右上腕	0.426	0.549	0.622	0.661	0.686	0.709
(12) 左手首	0.617	0.703	0.744	0.769	0.790	0.802
(13) 右手首	0.506	0.605	0.663	0.691	0.714	0.726
(14) 左足指	0.556	0.663	0.718	0.754	0.774	0.791
(15) 右足指	0.624	0.684	0.713	0.743	0.760	0.777
全体平均	0.548	0.659	0.718	0.756	0.786	0.805

デル化した式  $PWV = \sqrt{\frac{E_{inc} \cdot h}{2r\rho}}$  がある。この式で、 $E_{inc}$  は増分弾性係数、 $h$  は血管の壁の厚さ、 $r$  は血管の半径、 $\rho$  は血液の密度を示している。つまり、事前にこれらのパラメータが分かれば PWV を推定できる。一方で、既知の身体部位において脈波を計測することで、既知距離間の脈波到達時間差から脈波伝搬速度を計算し、血管年齢などの健康指標を算出する技術がある。特に、Brachial-ankle Pulse Wave Velocity は簡単に上腕と足首で脈波を測定できる有用な方法とされている [30]。これに加えて、ユーザの年齢を入力すれば、血管図が異常でない限り、事前に構築した他人のモデルに対して適合できると考える。

また、血圧および脈拍数と PWV の関係も報告されている。血圧の上昇により血管壁張力が増し、血管としての弾力性はなくなるため、PWV は高値になることが知られている。また、PWV は脈拍数の増加に伴い早くなることが 22 人の被験者実験により確認されている [31]。同一人物でも脈拍数が上昇したり、日や時間、体調によって血圧が変化するため、このような条件にも対応する必要がある。

## 6. おわりに

本研究では、心電と脈波のピークの時間差を用いてウェアラブルデバイスの装着位置を推定する手法を提案した。提案手法は心電の時間と脈波の到達時間の差を計算し、その時間差を用いて装置位置を推定する。提案手法はデバイスを装着するだけで装着位置を推定できる。5 名の被験者に身体部位 15 箇所の心電と脈波を計測して評価実験を行った。その結果、F 値の平均が 0.805 となった。特に、ユーザがデバイスを装着してから約 20 秒間待つと、左耳および右手指は F 値が 0.9 を超えた結果が得られた。

今後は各身体部位で脈波到達時間に違いを発生させて位置推定の精度を向上させるような姿勢を定義する。また、今回は同年齢の被験者からデータを収集した。そのため、年齢の違いによって変化があるかどうかを検証する。加えて、装着者ごとの血圧の違いや運動後などウェアラブルデバイス装着時の環境の違いによる変化も検証していく。また、ユーザに依存せずに位置推定できるモデルの提案を行っていく。

## 参考文献

- [1] M. Kunita and K. Iwata: Wearable biomedical monitoring system using textilenet, In ISWC 2006, pp. 119–120 (2006).
- [2] C.L. Shen, T. Kao, C.T. Huang, and J.H. Lee: Wearable band using a fabric-based sensor for exercise eeg monitoring, In ISWC 2006, pp. 143–144 (2006).
- [3] K. Ouchi, T. Suzuki, and M. Doi: Lifeminder: A wearable healthcare support system using user's context, In IWSAWC 2002, pp. 791–792 (2002).
- [4] T. Stiefmeier, G. Ogris, H. Junker, P. Lukowics and G. Tröster: Combining motion sensors and ultrasonic hands trac, king for continuous activity recognition in a maintenance scenario, In ISWC 2006, pp. 97–104 (2006).
- [5] Ryo Izuta, Kazuya Murao, Tsutomu Terada, and Masahiko Tsukamoto: Early Gesture Recognition Method with an Accelerometer, International Journal of Pervasive Computing and Communications, Vol. 11, No. 3, pp. 270–287 (2015).
- [6] Hsin-Liu(Cindy) Kao, Christian Holz, Astra Roseway, Andres Calvo, and Chris Schmandt: DuoSkin: Rapidly Prototyping On-Skin User Interfaces Using Skin-Friendly Materials, In ISWC 2016, pp. 16–23 (2016).
- [7] Yuki Yamamoto, Shingo Harada, Daisuke Yamamoto, Wataru Honda, Takayuki Arie, Seiji Akita, and Kuniharu Takei: Printed Multifunctional Flexible Device with an Integrated Motion Sensor for Health Care Monitoring, Science Advances, Vol. 2, No. 11, pp. e1601473 (2016).
- [8] K. Van Laerhoven and H.-W. Gellersen: Spine versus porcupine: a study in distributed wearable activity recognition, In ISWC 2004, pp. 142–149 (2004).
- [9] Kai Kunze and Paul Lucowicz: Sensor Placement Variations in Wearable Activity Recognition, IEEE Pervasive Computing, Vol. 13, No. 4, pp. 32–41 (2014).
- [10] Artem Dementyev, Hsin-Liu (Cindy) Kao, Inrak Choi, Deborah Ajilo, Maggie Xu, Joseph A. Paradiso, Chris Schmandt, and Sean Follmer: Rovables: Miniature On-Body Robots As Mobile Wearables, In UIST 2016, pp.111–120 (2016).
- [11] Artem Dementyev, Javier Hernandez, Sean Follmer, Inrak Choi, and Joseph Paradiso: SkinBot: A Wearable Skin Climbing Robot, In UIST 2017 Adjunct, pp. 5–6 (2017).
- [12] Hamidreza Bayati, Jose del R. Millán, and Ricardo Chavarriga: Unsupervised Adaptation to On-body Sensor Displacement in Acceleration-Based Activity Recognition, In ISWC 2011, pp. 71–78 (2011).
- [13] Alireza Vahdatpour, Navid Amini, and Majid Sarrafzadeh: On-body Device Localization for Health and Medical Monitoring Applications, In PerCom 2011, pp. 37–44 (2011).



- [14] 高田将志, 中村優吾, 藤本まなと, 荒川 豊, 安本慶一: メニュー推薦に向けたセンサ取り付け位置に依存しない自重トレーニング種目認識手法の提案, マルチメディア, 分散, 協調とモバイルシンポジウム (DICOMO 2018), pp. 780–790 (2018).
- [15] Kazuya Muraio, Haruka Mogari, Tsutomu Terada and Masahiko Tsukamoto: Evaluation function of sensor position for activity recognition considering wearability, In HASCA2013, pp. 623–632 (2013).
- [16] Louis Atallah, Benny Lo, Rachel King and Guang-Zhong Yang: Online pose classification and walking speed estimation using handheld devices, IEEE Transactions on Biomedical Circuits and Systems, Vol. 5, No. 4, pp. 320–329 (2011).
- [17] Apiwat Henpraserttae, Surapa Thiemjarus, and Sanparith Marukatat: Accurate Activity Recognition using a Mobile Phone regardless of Device Orientation and Location, In BSN 2011, pp. 41–46 (2011).
- [18] Timo Szttyler, Heiner Stuckenschmidt, and Wolfgang Petrich: Position-aware Activity Recognition with Wearable Devices, Pervasive and Mobile Computing, Elsevier, Vol. 38, pp. 281–295 (2017).
- [19] Kai Kunze, Paul Lukowicz, Holger Junker, and Gerhard Troster: Where am I: Recognizing On-body Positions of Wearable Sensors, In LoCA 2005, pp. 264–275 (2005).
- [20] 渡辺穂高, 梶 克彦, 河口信夫: 加速度・角速度を用いたセンサデバイスの装着位置・方向推定手法, 情報処理学会第74回全国大会, Vol. 2012, No. 3, pp. 359–360 (2012).
- [21] Doruk Coskun, Ozlem Durmaz Incel, and Atay Ozigovde: Phone Position/Placement Detection using Accelerometer: Impact on Activity Recognition, In ISSNIP 2015, pp. 1–6 (2015).
- [22] Henar Martin, Ana M. Bernardos, Josue Iglesias, and Jose R. Casar: Activity logging using lightweight classification techniques in mobile devices, Personal and Ubiquitous Computing, Vol. 17, No. 4, pp. 675–695 (2013).
- [23] Kaori Fujinami, Satoshi Kouchi, and Yuan Xue: Design and Implementation of an On-body Placement-Aware Smartphone, In ICDCS 2012 Workshop, pp. 69–74 (2012).
- [24] 倉沢 央, 川原圭博, 森川博之, 青山友紀: センサ装着場所を考慮した3軸加速度センサを用いた姿勢推定手法, 情報処理学会研究報告(コピキタスコンピューティングシステム研究会), Vol. 11, No. 3, pp. 15–22 (2006).
- [25] Jun-geun Park, Ami Patel, Dorothy Curtis, Seth Teller, and Jonathan Ledlie: Online pose classification and walking speed estimation using handheld devices, In UbiComp 2012, pp. 1–6 (2015).
- [26] LR. Mikael, AMG. Paiva, MM. Gomes, ALL. Sousa, PCBV. Jardim, PVO. Vitorino, MB. Euzébio, WM. Sousa, WKS. Barroso, and Arq Bras Cardiol: Vascular Aging and Arterial Stiffness, Vol. 109, No. 3, pp. 253–258 (2017).
- [27] Robert Durichen, Keshav Deep Verma, Seow Yuen Yee, Thomas Rocznik, Philip Schmidt, Joschka Bödecker, and Christian Peters: Prediction of Electrocardiography Features Points using Seismocardiography Data: A Machine Learning Approach, In ISWC 2018, pp. 96–99 (2018).
- [28] S. Kullback and R.A. Leibler: On Information and Sufficiency, Ann. Math. Statist., Vol. 22, No. 1, pp. 79–86 (1951).
- [29] R.G. Gosling and M.M. Budge: Terminology for Describing the Elastic Behavior of Arteries, Hypertension, Vol. 41, No. 6, pp. 1180–1182 (2003).
- [30] M. Munakata: Brachial-Ankle Pulse Wave Velocity: Background, Method, and Clinical Evidence, Pulse (Basel), Vol. 3, No. 3–4, pp. 195–204 (2016).
- [31] P. Lantelme, C. Mestre, M. Lievre, A. Gressard, and H. Milon: Heart rate: an important confounder of pulse wave velocity assessment, Hypertension, Vol. 39, No. 6, pp. 1083–1087 (2002).