

足取り取得による パーソナリティを考慮したユーザ状態の推定

植村 喜弘^{1,a)} 梶原 祐輔^{1,b)} 島川 博光^{1,c)}

受付日 2015年2月3日, 採録日 2015年9月2日

概要: 近年, おもてなしの提供が求められている. おもてなしの提供には, ユーザの状態やパーソナリティを把握する必要がある. 本論文では, おもてなしの提供のために, Radio Frequency Identifier (RFID) 技術で取得される足取りの特徴から, ユーザの状態やパーソナリティを推定する手法を提案する. 15名の被験者における6種のユーザ状態での歩行データを取得した実験で, パーソナリティごとの足取りの特性を本手法で識別できることが分かった. パーソナリティが現れたクラスごとに機械学習することで, クラスタリングしない場合と比較し, ユーザ状態を把握する精度が4.3%向上した. 本論文では, 識別結果および足取りの解析から, パーソナリティを考慮することによる精度向上に影響を与える成分について議論する.

キーワード: おもてなし, 足取り, RFID, パーソナリティ, ユーザ状態

Estimating Traveler Status from Gait Features Considering Personality

YOSHIHIRO UEMURA^{1,a)} YUSUKE KAJIWARA^{1,b)} HIROMITSU SHIMAKAWA^{1,c)}

Received: February 3, 2015, Accepted: September 2, 2015

Abstract: The modern society full of convenience demands proactive hospitality. To achieve it, it is indispensable to grasp states and personality of each user. The paper proposes a method to estimate states and the personality of the user to provide proactive hospitality from features of his/her gait pattern acquired with Radio Frequency Identifier (RFID) technologies. An experiment, collecting walking data in 6 states from 15 subjects, has proved that the method succeeds in the estimation of personality. The machine learning for each personality improves the accuracy of the identification of user states by 4.3% compared with a method neglecting personality.

Keywords: proactive hospitality, gait, RFID, personality, states of user

1. はじめに

近年, 訪日外国人観光客が増加傾向にあり, 2013年度には1,000万人を超過した [1]. 観光立国推進戦略会議は, 2020年までに2,000万人の訪日外国人観光客を目標とし, 高品質な観光を提供するとしている [2]. 同時にそのためには観光客がおもてなしを実感できる必要があるとしてい

る [3]. おもてなしとは, 顧客の状態や性格を把握し, 顧客が求めているサービスを求められる前にその場で提供することである. 観光客が日本でたのしみに行っている主な活動としてショッピングがあげられる [4]. そこで我々は, 多くの観光客が訪れるショッピングモールでのおもてなしに着目する. しかし, ショッピングモールを訪れる観光客それぞれにおもてなしを提供することは不可能である. これは顧客に対するおもてなし提供者の育成や配置に多大なコストがかかるからである. したがってICTを用いて, 低コストでおもてなしを提供するシステムが必要である. 自動車運転の時間帯や曜日などからドライバのニーズを予測する

¹ 立命館大学
Ritsumeikan University, Kusatsu, Shiga 525-8577, Japan
a) y_uemura@de.is.ritsumei.ac.jp
b) kajiwara@de.is.ritsumei.ac.jp
c) simakawa@is.ritsumei.ac.jp

システム [5] の開発が、2018 年以降の実用化を目指して進められている。しかし、ショッピングモールでは、ICT を用いた観光客へのおもてなしは少ない。

本論文では、ショッピングモールでの ICT を用いたおもてなしとして、以下に示す 2 種を考える。

- なんらかの要因によって荷物に対する不快さに苦しんでいる観光客、疲労している観光客に対する気遣い。
- 注意が散漫になっている観光客に安全に観光してもらうための安心・安全の提供。

たとえば、お土産の家電など重い荷物を持っているような観光客には、ロッカーや荷物預かり所を推薦し、エレベータなど移動手段のある場所を通知する。長時間のショッピングで疲労している観光客には、休憩所やカフェ、交通手段を推薦する。スマホや広告を見ながらの余所見歩きをしている観光客は、危険なので注意を促す。また、サービスの提供の仕方や頻度も変える必要がある。たとえば、主観性の高いユーザであれば、自身で目的を持って行動するので、推薦の頻度を減らす。逆に、主観性の低いユーザであれば、推薦の頻度を増やす。ユーザの性格などを把握することで、より高品質なおもてなしを実現することができる。以降、おもてなしに必要な顧客の状態をユーザ状態、性格をパーソナリティと呼ぶ。人通りの多い通路や、ショーウィンドウの前など、限られたエリアを想定し、足の運び方である足取りからこれらを推定する。本論文ではその方法および、それを用いてパーソナリティごとにユーザ状態を推定する手法を提案する。また、ユーザ状態の推定に重要な役割を果たす成分について議論する。

2. 関連研究

おもてなしは、事前にユーザ状態やパーソナリティを把握し、それに応じたサービスをその場で提供することで実現される。今回、おもてなし提供に必要なユーザ状態として、荷物を持っている状態、歩きスマホをしている状態、広告に注目している状態、疲労している状態を考える。

上記のユーザ状態を検知する既存研究をあげる。Ikeda らは、Laser Range (以降 LR) センサを複数台用いて、取得された 3 次元情報からバックパックやカートなどを識別している [6]。Qi らは、カメラを用いて人物のシルエットを検出し、主軸における左右比から、バックパックやキャリーケースなど、荷物を識別している [7]。Yonekawa らは、靴の中敷きに設置された圧力センサにおける最大圧力の低下や変遷などから疲労を検知するシステムを構築した [8]。Arif らは、加速度センサを用いて疲労が歩行の安定性に影響があることを示した [9], [10]。Music らは、スマートフォン内蔵の加速度センサ値の標準偏差から歩きスマホを検知している [11]。Thepvilojanapong らは、LR センサを用いて人の判別や移動、滞留などから展示物への注目度を算出

した [12]。Clippingdale, Naemura らは、TV 内蔵カメラを用いて、顔の向きや表情、上半身の向きなどから注目状態を検知し、興味を推定している [13], [14]。次にパーソナリティを推定する既存研究をあげる。Roshchina らは、複数のレビュー履歴からパーソナリティを推定する手法を提案し、他の手法と比較した [15], [16]。Minamikawa らは、ブログ履歴からパーソナリティを推定する手法を提案した [17]。カメラはプライバシー侵害の問題があり [18]、さらに遮蔽物に弱いので、今回適用するような人の多い環境には適さない。LR センサは高額で、複数台設置することが難しい。

荷物や疲労など、ユーザ状態において足取りは異なる [19], [20], [21]。また、足取りにパーソナリティが現れるという研究がある [22]。ここで、足取りとして、歩幅、歩速などが考えられる。たとえば歩幅の計測には高精度な位置情報が必要である。したがって、圧力センサだけのおもてなしを実現することはできない。加速度センサを利用したデッドレコニング手法が提案されている [23]。また、スマートフォンによる Bluetooth や無線 LAN を利用した位置検出も考えられる [24], [25]。しかし、これらの位置検出精度は約 1m 以上であり、正確に歩幅を計測することはできないと考えられる。したがって、高精度な位置情報を持ち、遮蔽物に強い足取りに着目する。Ibara, Oikawa らは、フロアマット型の圧力分布センサを用いて、歩幅などの足取りを検出している [26], [27]。しかし、圧力センサは単位面積あたりの価格が高額で、店舗側が複数の場所で設置することは困難である。Aminian らは慣性センサを利用して歩容を分析している [28]。慣性センサは 1 台あたりが高額で、本論文で想定する一度に多人数が利用するような環境の場合、導入コストが非常に高い。つまり、低コストで複数のユーザ状態および高精度な位置を把握するシステムが必要である。足取りの検出には、足が接地した位置を高精度で検出する必要がある。Choi らは RFID を用いて自律移動型ロボットの位置を正確に把握している [29], [30]。Wang らは歩行者の位置検出に RFID を用いたハイブリッドセンサを利用している [31]。これらの研究から RFID は高精度の位置検出が可能であることが分かる。RFID を用いた足取りの検出はされていない。

3. パーソナリティを考慮したユーザ状態推定手法

本研究では安価な RFID を用いた足取りの検出を考える。パーソナリティ推定の既存研究はユーザ状態を同時に推定することができない。今回我々は、単一のセンサを用いてパーソナリティを推定するシステムを提案する。単一センサによる推定のため、コストを抑えることができる。しかし、既存研究と本研究の成果を組み合わせることにより、より高精度にパーソナリティを推定することができる

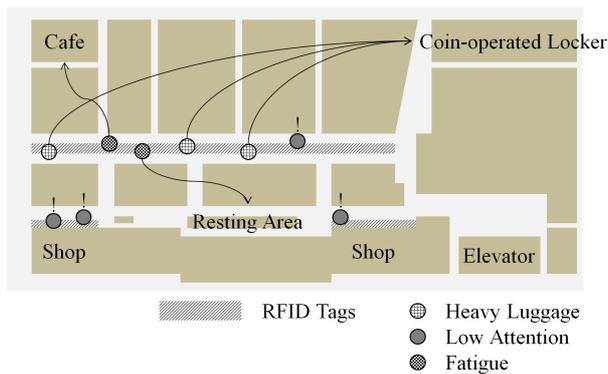


図 1 提案システム設置場所およびサービス例
 Fig. 1 Services in actual environment.

表 1 提案システムを用いたサービス例
 Table 1 Service examples.

ユーザ状態	サービスの一例
荷物を所持	コインロッカーの場所までの経路を提示する.
歩きスマホ	危険なので立ち止まってスマホを操作するように注意を促す.
広告に注目	休日など混雑している日は周囲に気をつけるように注意を促す.
疲労	休憩スペースの場所までの経路を提示する.

と考えられる. 本手法で提案するシステムを用いたサービス提供例を図 1, 具体的なサービス例を表 1 に示す.

ユーザごとに推定されたユーザ状態およびパーソナリティに適したサービスを提供する. 本システムでは, ユーザは RFID リーダを足に設置する. RFID リーダは 2,000 円弱, RFID タグは 1 枚あたり数十円と安価である. また, タグの配置のみでシステムの利用範囲が拡大できるため, 拡張性が高い. 我々は, ショッピングモール側が観光客にアンクレットのような着脱式のリーダを貸し出し, 人通りの多い通路やショーウィンドウの前にタグを設置することを想定する. これらにより, ユーザに合った推薦やサービスを提供することで, ユーザは心地良いおもてなしを実感することができる. これはリピータの獲得や, 新規顧客の獲得につながると考えられる. また, 注目状態からユーザの商品に対する注目度が算出できる. これにより, 顧客層などが分かり, サービスの向上につなげられる.

本研究では, ユーザ状態およびパーソナリティを足取りから推定する. 2 章でパーソナリティが足取りに表れることを示した研究をあげた. これは, パーソナリティごとに足取りが異なることを示している. パーソナリティを考慮しないと, 汎化性能が落ちる可能性がある. したがって, パーソナリティごとに学習し, 識別する. ユーザをパーソナリティごとに分け, ユーザ状態を推定する手法を図 2 に示す.

手法は以下の手順で行う.

- 1) センサを用いて足が地面に接した位置を基に各足取り

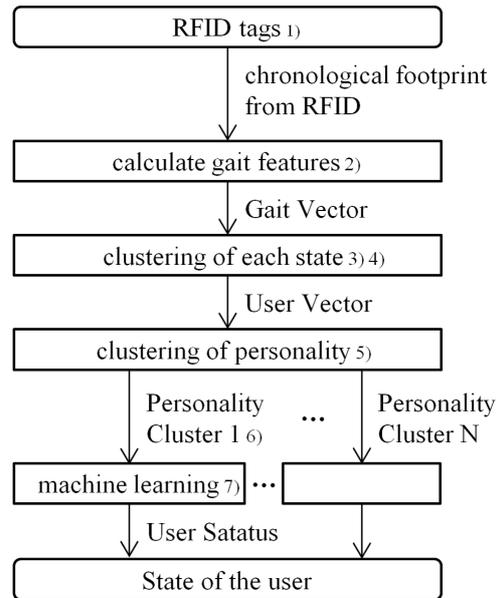


図 2 パーソナリティを考慮したユーザ状態推定
 Fig. 2 State estimation considering personality.

を時系列順に取得する.

- 2) その足取りから足取りの特徴を成分とした足取りベクトルを算出する.
- 3) 各ユーザ状態において, 足取りベクトルをクラスタリングする.
- 4) クラスタリング結果を成分としたユーザベクトルを作成する.
- 5) ユーザベクトルをクラスタリングし, 足取りの似たユーザごとにクラスタを構成する.
- 6) 5) で抽出したクラスタに属するユーザの性格からそのクラスタの代表的なパーソナリティを決定する. この紐付けされたクラスタをパーソナリティクラスタと呼称する.
- 7) パーソナリティクラスタごとに機械学習し, ユーザ状態識別のための学習器を作成する.

新規ユーザは, 新規ユーザから抽出したユーザベクトルと各パーソナリティクラスタの中心を比較し, 最も近いパーソナリティクラスタに属するとする. 新規ユーザのパーソナリティは, 属するパーソナリティクラスタの代表パーソナリティとして推定される. 所属するパーソナリティクラスタでの学習器を用いて, ユーザ状態を推定する.

3.1 RFID を用いた着地位置の検出

RFID とはリーダと固有 ID を持つタグによる近距離無線通信技術である [32]. 今回は通信距離が数 cm 程度の HF 帯の RFID を用いる. 本手法では, 図 3 のように縦横 5.0 cm ごとに 4.5 cm 四方のタグを敷き詰めたタグシートを床面に敷設する. ユーザは靴のつま先からかかとの方向に 5.0 cm の位置にリーダを装着して歩行する. リーダが読

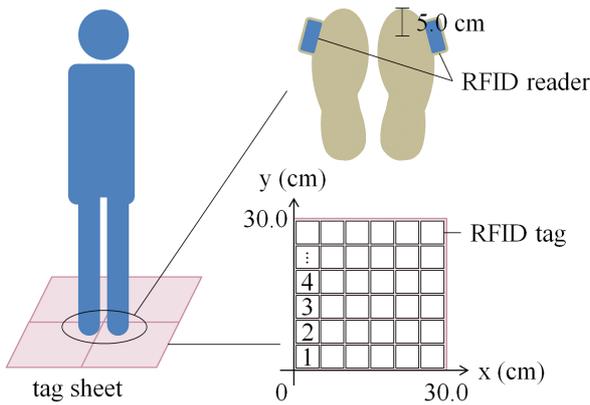


図 3 RFID を用いた位置検出システム
Fig. 3 Position detection using RFID.

み込んだタグの固有 ID から足の着地位置を計算する。歩行したさいは、リーダから取得される着地位置を時系列に従って取得する。リーダのサンプルレートは 1 検出あたり 0.2~0.25 秒である。本研究では、図 3 に示すように両足にリーダを装着している。歩行速度は約 4.0 km/h、片足の現在と次の 1 歩との距離である重複歩距離は約 120~180 cm である [33]。歩行速度を秒速に直したもので重複歩距離を除算すると、1 重複歩あたりの時間が約 1.1~1.6 秒と算出される。以上から本研究のリーダはユーザ状態により 5 倍程度歩速が変わった場合まで足取りの測定が可能である。

3.2 取得データのクラスタリング

通信距離内にタグとリーダが存在した場合、リーダはつねにタグを読み続ける。そのため、リーダが地面に対して緩やかな角度で着地・離地する場合、1 歩の移動において複数のタグの検出位置が取得される。そこで、タグの検出位置をクラスタリングし、各クラスタをユーザの 1 歩とする。クラスタリングとして、群内分散と群間分散の比を利用した階層的クラスタ分析手法である ward 法 [34] を用いる。また、クラスタリングでは、2 群の重心間のユークリッド距離が閾値以上のクラスタを 1 歩とする。これにより一定区間内で歩数が異なった場合にも提案手法は対応可能である。分類されたクラスタをステップクラスタと呼ぶ。

3.3 足取りの特徴決定

ユーザ状態による足取りの変化として以下が考えられる。重い荷物を持っているさい、重心位置がずれふらふらした歩き方になり、それを制御しようと、歩幅が小さくなり歩速が遅くなる。何かに注目しているさい、ゆっくりとした足取りになり歩速が遅くなる。加えて、本来の進行方向からそれる。疲労しているさい、足取りが重くなり、足が接地している時間が延びる。また、パーソナリティによって提供するサービスも変わると考えられる。たとえば、キビキビしたユーザへは効率性を重視したサービスを提供する必要がある。人に対して開放的なユーザへは人を介した

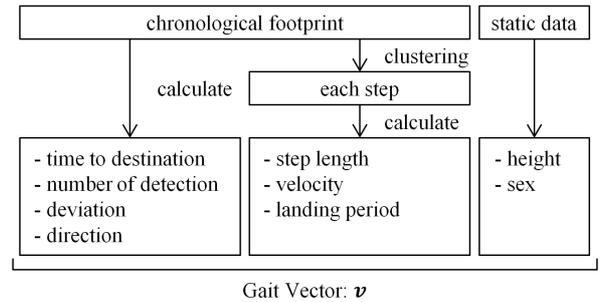


図 4 足取りベクトル詳細図
Fig. 4 Gait Vector.

サービスの提供が効果的である。よっておもてなしを提供するためにはパーソナリティを把握する必要がある。本研究では、ユーザ状態を識別するために、足取りの変化の特徴を成分とした足取りベクトル v を定義する (図 4)。

一定区間内の N 個のステップクラスタから歩行時間、タグの総検出数、ぶれ、傾き、着地時間、歩幅、歩速を算出する。算出法を以下に示す。歩行時間 w_t は一定距離における時刻の始点 t_b と終点 t_e との差である。

$$w_t = t_e - t_b$$

i ($1 \leq i \leq N$) 番目のクラスタの中で j 番目に検出されたタグを考える。 $n_g(i)$ をクラスタ i に含まれる検出されたタグ数とすると、タグの総検出数は $\sum_{i=1}^N n_g(i)$ と表される。ユーザの進行方向を y 軸正方向とし、それを時計回りに 90° 回転させた方向が x 軸正方向とする。検出される座標を $(g_x(i, j), g_y(i, j))$ とすると、ユーザがぶれなく歩いたとき $g_x(i, j)$ は変化しないので、ぶれ g_{dev} は検出される x 座標の標準偏差で、以下の式で表される。

$$g_{dev} = \sqrt{\sum_i \sum_j g_x(i, j)^2}$$

y 座標を目的変数、 x 座標を説明変数にした回帰直線の傾きを a とおく。クラスタ i 内の最初のタグの検出時刻を $g_t(i, b)$ 、最後のタグの検出時刻を $g_t(i, e)$ とおく。着地時間 $g_t(i)$ は以下の式で表される。

$$g_t(i) = g_t(i, e) - g_t(i, b)$$

ここで歩幅の算出方法は複数考えられる。

- 分類されたステップクラスタの中心間の距離 w_{w_1}
- 分類されたステップクラスタの着地位置間の距離 w_{w_2}
- 分類されたステップクラスタの離地位置間の距離 w_{w_3}
- 分類されたステップクラスタの着地位置から離地位置間の距離 w_{w_4}
- 分類されたステップクラスタの離地位置から着地位置間の距離 w_{w_5}

i 番目のステップクラスタを $c_w(i)$ とおく。 $c_w(i)$ 内の検出されたタグのそれぞれから算出された座標には、検出された時刻が関係づけられる。クラスタの内部詳細を図 5 に

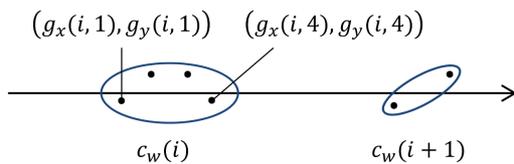


図 5 クラスタ内部詳細

Fig. 5 Distance between clusters.

示す。 $w_{w_1}(i)$ は、 i ($1 \leq i \leq N-1$) 番目と $i+1$ 番目のステップクラスタ中心間のユークリッド距離である。 $w_{w_2}(i)$ は、 i 番目と $i+1$ 番目のクラスタ内で、時刻がともに最小値である座標のユークリッド距離である。 $w_{w_3}(i)$ は、 i 番目と $i+1$ 番目のクラスタ内で、時刻がともに最大値である座標のユークリッド距離である。 $w_{w_4}(i)$ は、 i 番目のクラスタ内の時刻が最小の座標と、 $i+1$ 番目のクラスタ内の時刻が最大である座標のユークリッド距離である。 $w_{w_5}(i)$ は、 i 番目のクラスタ内の時刻が最大の座標と、 $i+1$ 番目のクラスタ内の時刻が最小である座標のユークリッド距離である。同様に歩速の算出方法も複数考えられる。

- 分類されたステップクラスタの中心間の歩速 w_{v_1}
- 分類されたステップクラスタの着地位置間の歩速 w_{v_2}
- 分類されたステップクラスタの離地位置間の歩速 w_{v_3}

これらは、歩行時間、歩幅を用いて以下の式で算出される。

$$w_{v_1} = \frac{\sum_{i=1}^{N-1} w_{w_1}(i)}{w_t}$$

$$w_{v_2} = \frac{\sum_{i=1}^{N-1} w_{w_2}(i)}{w_t}$$

$$w_{v_3} = \frac{\sum_{i=1}^{N-1} w_{w_3}(i)}{w_t}$$

以上の成分を片足の足取りベクトルと定義する。本手法では両足について同様の計算をし、足取りベクトルを拡張する。さらにアンケートから身長 h および性別を足取りベクトルに加える。

3.4 主要な成分の抽出とクラスタリング

歩き方はユーザごとに異なるため、個人ごとにシステムを構成する必要がある。しかし、個人ごとにシステムを構成するにはユーザへの負担が大きい。そこで、歩き方の似たユーザ群をあらかじめ用意し、そのユーザに近いユーザ群を基準としてユーザ状態を推定する。ユーザ群のパーソナリティを基準としておもてなしを提供する。したがって、歩き方の似たユーザ群ごとに分ける必要がある。足取りベクトルのうち、ユーザ状態の推定に対してノイズを含む成分を除く必要がある [35]。これはユーザごとに分けるさい、誤った分類を避けるためである。足取りベクトルを説明変数とし、機械学習手法 Random Forest (RF) [36] を用いて学習する。RF は樹木モデルを用いた集団学習手法で、大量の決定木に識別パターンを学習させる手法である。

RF では決定木ごとに説明変数をランダムに選択し、学習する。学習するさい、親と子のジニ係数の差が最大になるように閾値を決定する。ジニ係数は不純さを示す尺度として用いられている。ジニ係数が大きいほど偏りのあるデータである。全決定木における根と子のジニ係数の差の合計を変数重要度とする。これが大きなベクトル成分を抽出する。

3.5 ユーザのクラスタリングと識別

ここでは、2段階のクラスタリングから足取りの似たユーザを分類する手法を示す。ユーザ状態ごとに、全ユーザの足取りベクトル成分を基に ward 法を用いてクラスタリングする。足取りベクトル成分は 3.4 節で抽出された成分を用いる。ユーザ状態の数を S とし、ある状態 s ($1 \leq s \leq S$) でのクラスタ数を N_s とする。ユーザごとにクラスタへ分類された足取りベクトルの数を成分とした $\sum_{s=1}^S N_s$ 次元のユーザベクトル u_k ($k \geq 1$) を算出する。

$$u_k = [c_{k1}(1) \cdots c_{ks}(i) \cdots c_{kS}(N_S)]^T$$

$c_{ks}(i)$ は、ユーザ k の状態 s における、 i ($1 \leq i \leq N_s$) 番目のクラスタへ分類された足取りベクトルの数である。この $c_{ks}(i)$ は入力される足取りベクトルの数に依存する。本論文では、データ数はユーザごとに一定であることを想定する。次に ward 法を用いて、ユーザベクトルをクラスタリングすることで、足取りの似たユーザを分類する。生成されたクラスタをパーソナリティクラスタ $c_p(i)$ と呼ぶ。パーソナリティクラスタごとに、足取りベクトルがどのようなユーザ状態に対応しているかを RF を用いて学習、識別する。RF によって状態を識別するには学習フェーズと識別フェーズが必要である。学習フェーズでは、パーソナリティクラスタごとに歩行から得られる足取りベクトルを教師信号として樹木モデルを作成する。識別フェーズでは、パーソナリティクラスタに対応する樹木モデルを用いて足取りベクトルに対応するユーザ状態を識別する。

3.6 パーソナリティの決定

パーソナリティクラスタごとに矢田部ギルフォード (YG) 性格検査 [37] を実施し、パーソナリティクラスタのパーソナリティを決定する。YG 性格検査は協調性や一般的活動性など 12 尺度を各 5 段階で表す。今回は 12 尺度のうち、おもてなしに必要であると考えられる以下に示す 5 つの尺度において、ユーザのパーソナリティを決定する。各尺度における得点は 5 が最も強くその性質を持っており、1 がそれとは逆の性質を持つことを示す。

- 主観的傾向示す主観性 O
- 人への警戒度を示す協調性 Co
- 短気さや積極性を示す攻撃性 Ag
- キビキビしているさまや俊敏性を示す活動性 G

● 物事をあまり気にせず気楽なことを示すのんき性 R
 おもてなしに関係のあると考えられる尺度において、5段階の結果からパーソナリティクラスタのパーソナリティを決定する。各パーソナリティクラスタに属するユーザにおいて、5段階の結果の共通項をそのクラスタのパーソナリティとする。また新規ユーザがシステムを利用する場合は、ユーザの足取りから近いユーザ群を推定し、そのユーザ群のパーソナリティをユーザのパーソナリティとする。

4. 実験

4.1 環境と方法

ユーザの足取りから本手法により推定されるパーソナリティクラスタにおいて以下2つを目的として実験した。

- ユーザ状態を推定する。
- パーソナリティを検証する。

本研究では、アートファイネックス社製の USB 型 RFID リーダ、ASI4000USB を使用する。周波数 13.56 MHz の HF 帯で、通信距離は 3.0 から 5.0 cm である。被験者は 21~24 歳の男性 12 名、女性 3 名である。被験者はつま先にリーダを装着し、USB ケーブルで CPU が Intel(R) Core(TM) i7-2677M, 4GB のメモリを持つ計算機へ接続し、位置情報を取得する。歩行区間を 10.0m とし、始点および終点での停止を考慮した前後 2.0m の予備区間を除く 6.0m にタグを敷設した (図 6)。

実験で推定するユーザ状態を以下に示す。

- S_N 無負荷、何も持っていない。
- S_{LB} 両手にそれぞれ荷物 5.0kg の入った手提げかばんを持つ。
- S_{LO} 右手に荷物 5.0kg の入った手提げかばんを持つ。
- S_T 携帯端末 (スマホ) でキュレーションマガジンサイトを閲覧する。
- S_A 歩行区間の中間地点のディスプレイに表示される広告に注目する。
- S_F 以下に示す疲労状態で、かつ、無負荷で何も持っていない。

S_F の疲労状態を作るために、1 秒間に 2 段のペースで階段を上り下りする。疲労の基準に、以下の式に示す Karvonen 法 [38] により算出される運動強度 H (単位: % HRR) を用いる [9], [10]。

$$H = \frac{C - R}{M - R} \times 100$$

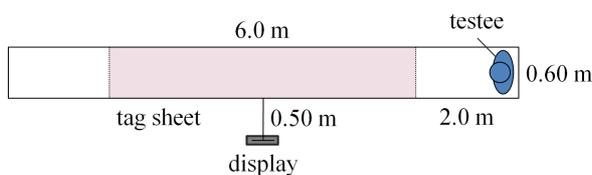


図 6 実験環境

Fig. 6 Experimental environment.

最大心拍数 M は 220 - 年齢 (単位: bpm) で算出し、安静時心拍数 R (単位: bpm) は、30 分間の着席安静状態後に計測する。現在の心拍数 C (単位: bpm) は秒単位で取得し、算出される H が 60% HRR を超えた回数が 600 回になるまで実施した。 S_N から S_F の状態における位置情報を各 50 回ずつ取得した。ただし、状態 S_N から S_A における疲労の影響を考慮し、状態の間に 30 分以上の休憩を設け、1 日あたり 1 ないしは 2 状態実験した。解析には統計解析ツール R を用いた。ward 法は hclust 関数、RF は randomForest 関数を用い、パラメータはデフォルト値とした。3.2 節で示したステップを分類するための群間の距離の閾値は、実際の歩様とクラスタリング結果が一致するよう、経験的に決定した。本研究ではこの閾値を 100 とする。3.5 節で示した各状態におけるクラスタ数は、以下の式により算出される分散比 r_{dev} の変化率が最も大きく変化する場所を基準に決定する。

$$r_{dev} = \frac{\text{群間変動の不偏分散}}{\text{群内変動の不偏分散}}$$

提案手法の有効性を検証するため、パーソナリティクラスタごとに、含まれる 1 名を test set、それ以外の人を training set として Cross-validation する。識別器には RF を用いる。また、この結果から適合率、再現率を求め、以下の式から算出される F 値 f で評価し、パーソナリティクラスタに分類しない場合と比較する。適合率は提案手法が推定したユーザ状態のうち、実際のユーザ状態と一致していた割合、再現率は実際のユーザ状態のうち、提案手法が推定したユーザ状態と一致していた割合である。加えて、ユーザ群ごとにパーソナリティを確認するため、YG 性格検査を実施する。

4.2 結果

今回、被験者の足取りベクトルを主座標分析すると、1 名が他の 14 名と離れていた。したがって、似た被験者がいないため、外れ値として除去した。3.4 節で示した RF で識別した場合 (以降 P とする) の f は、 S_N が 0.146, S_{LB} が 0.338, S_{LO} が 0.144, S_T が 0.155, S_A が 0.535, S_F が 0.136, 平均で 0.243 となった。このときの変数重要度が両足の平均値 1137 より高い成分を表 2 に示す。簡略化のため、歩幅 $w_{w_5}(i)$ の平均値を $\overline{w_{w_5}(i)}$ とし、以降これを歩幅と呼ぶ。これらの成分を基に各ユーザ状態において足取りベクトルをクラスタリングし、ユーザベクトルを算出する。クラスタリングには ward 法を用いる。クラスタ数の決定は 4.1 節で示した分散比 r_{dev} の変化率を用いる (図 7)。このユーザベクトルを ward 法によりクラスタリングし、3.5 節で示したパーソナリティクラスタを算出する。今回、パーソナリティクラスタは 3 個、 $c_p(1)$, $c_p(2)$, $c_p(3)$ となった、これはユーザベクトル算出と同様に分散比 r_{dev} を用いて決定した (図 8)。また、パーソナリティ

表 2 変数重要度 (小数第 3 位四捨五入)

Table 2 Variable importance.

動の変数	右足	左足	静の変数	アンケート
w_t	1164.96		h	1533.80
g_{dev}	1657.36	1619.87		
$w_{w_3(i)}$	1258.87	1296.67		
w_{v_1}	1991.26	2085.35		
w_{v_2}	1691.19	1568.61		
w_{v_3}	1421.50	1501.84		

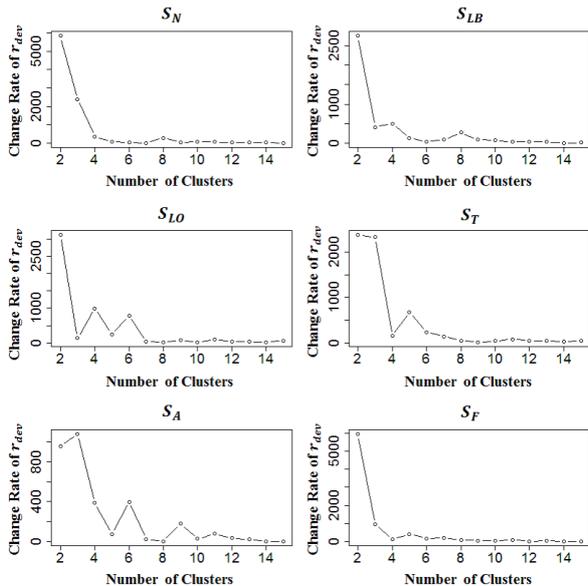


図 7 群内および群間分散の変化率推移 (1)

Fig. 7 Variance within-group and between-group (1).

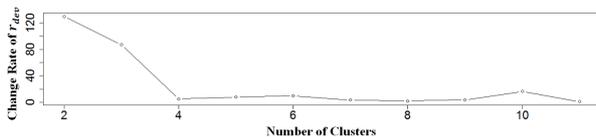


図 8 群内および群間分散の変化率推移 (2)

Fig. 8 Variance within-group and between-group (2).

クラスタごとの YG 性格検査結果を図 9 に示す。

以上から、クラスタごとの YG 性格検査によるパーソナリティの傾向を表 3 に示す。それぞれのパーソナリティクラスタにパーソナリティが表れていることが分かる。パーソナリティの傾向から、 $c_p(1)$ は親しみやすい性格なので、 $c_p(frd)$ と表記する。 $c_p(2)$ は優柔不断な性格であり、 $c_p(ind)$ と表現する。 $c_p(3)$ はのんきな性格を持っており、 $c_p(eg)$ で表す。

パーソナリティクラスタに分割しない場合と、分割した場合の識別結果を表 4、表 5 に示す。また、これらから算出される f を表 6 に示す。ユーザをクラスタリングした場合、クラスタリングした場合の f の平均値は 0.286 ± 0.217 である。クラスタリングしない場合 P における f の平均値は 0.243 ± 0.229 である。また、それぞれの平均値はラ

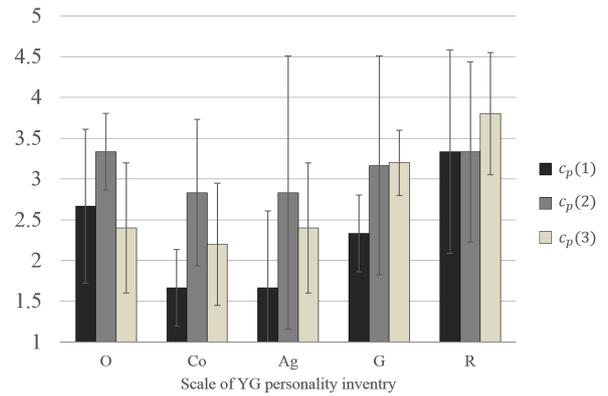


図 9 YG 性格検査結果 (Point)

Fig. 9 Result of YG personality inventory.

表 3 各クラスタのパーソナリティ傾向

Table 3 Personality in each cluster.

	パーソナリティ傾向
$c_p(1)$	<ul style="list-style-type: none"> ● Co の得点が非常に低いことから、人に対して協調的である ● Ag の得点が非常に低いことから、温厚である ● G の得点が低いことから、おとなしい
$c_p(2)$	<ul style="list-style-type: none"> ● O の得点が 3 付近であることから、主観的・客観的双方の見方が得意もしくはその逆である
$c_p(3)$	<ul style="list-style-type: none"> ● O の得点が低いことから、客観的な見方が得意である ● Co の得点が低いことから、人に対して協調的である ● Ag の得点が低いことから、消極的である ● G の得点が 3 付近であることから、心身両面での活発さが中程度である ● R の得点が高いことから、物事をあまり気にしない

ンダム値 0.167 よりも高い。 $c_p(frd)$ 、 $c_p(ind)$ 、 $c_p(eg)$ の f の平均値はそれぞれ、0.323、0.284、0.229 で、 $c_p(frd)$ 、 $c_p(ind)$ は P と比較して高い。

5. パーソナリティごとの分析

5.1 概要

4.2 節からユーザ状態の識別精度が 4.3% 向上していることが分かる。したがって、ユーザをクラスタリングすることで、識別精度が向上する。これはパーソナリティを持つ各パーソナリティクラスタについて、ユーザ状態に表れる足取りの特徴が異なるためであると考えられる。これを検証するために、ユーザ状態の識別でクラスタリングしない場合と比較して変化のあるユーザ状態を見つける。そのユーザ状態における変数重要度の高い足取りベクトル成分の特徴、およびパーソナリティとの関係を考察する。

5.2 有意性の検証

パーソナリティクラスタに分割することに対する有意性を検証する。 P およびパーソナリティクラスタに分割した場合において、14 名の被験者における各状態での f を入力

表 4 パーソナリティクラスタに分割しない場合の適合率・再現率 (有効数字 3 桁に四捨五入)

Table 4 Precision and recall without clustering.

k	precision						recall					
	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F
1	0.313	0.390	0.450	0	0.511	0.235	0.420	0.460	0.540	0	0.940	0.080
2	0.350	0.841	0	0.174	0.378	0.355	0.280	0.740	0	0.080	0.960	0.440
3	0	0.245	0	0.111	0.852	0	0	0.960	0	0.020	0.460	0
4	0.167	0.337	0.258	0.304	0.300	0.405	0.040	0.680	0.340	0.420	0.060	0.340
5	0.152	0.0313	0.188	0	0.409	0.129	0.100	0.020	0.120	0	0.760	0.080
6	0.232	0.571	0	0	1.00	0.028	0.840	0.160	0	0	0.880	0.020
7	0.583	0.923	0	0.010	0.331	0.280	0.140	0.480	0	0.020	0.920	0.140
8	0.500	0.188	0.194	0.414	0.923	0.024	0.020	0.420	0.140	0.580	0.720	0.020
9	0.155	0.137	0.133	0.167	1.00	0.111	0.220	0.280	0.160	0.040	0.380	0.080
10	0.222	0.159	0.309	0.500	0	0.026	0.080	0.280	0.760	0.320	0	0.020
11	0	0.737	1.00	0.227	0.451	0	0	0.280	0.020	0.740	0.640	0
12	0.250	0.269	0.192	0.714	0.603	0.500	0.140	0.780	0.100	0.100	0.940	0.160
13	0.063	0.500	0	0	0.208	0.179	0.020	0.040	0	0	0.620	0.100
14	0.044	0.202	0.194	0.389	0.661	0.289	0.060	0.340	0.140	0.140	0.740	0.220

表 5 パーソナリティクラスタに分割した場合の適合率・再現率 (有効数字 3 桁に四捨五入)

Table 5 Precision and recall with clustering.

k	cluster	precision						recall					
		S_N	S_{LB}	S_{LO}	S_T	S_A	S_F	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F
1	eg	0.444	0.071	0.381	0	0.314	0.466	0.160	0.020	0.320	0	1.00	0.540
2	ind	0.303	0.816	0.593	0.636	0.592	0.315	0.400	0.620	0.320	0.560	0.840	0.340
3	frd	0.370	0.270	0.340	0.276	0.580	0.389	0.200	0.340	0.360	0.320	0.940	0.140
4	ind	0.167	0.270	0.101	0	0.250	0.355	0.020	0.340	0.300	0	0.020	0.220
5	ind	0.407	0.036	0.327	0	0.266	0.321	0.220	0.060	0.360	0	0.340	0.180
6	eg	0.240	0.571	0	0	1.00	0.111	0.720	0.080	0	0	0.560	0.180
7	ind	0.321	0.853	0.573	0	0.529	0.320	0.360	0.580	0.940	0	0.540	0.480
8	frd	0.600	0.091	0.226	0.579	1.00	0.0638	0.060	0.100	0.140	0.440	0.600	0.180
9	frd	0.110	0.214	0.122	0.133	1.00	0.231	0.260	0.06	0.180	0.080	0.500	0.180
10	eg	0.171	0.117	0.396	0.250	0.091	0.289	0.140	0.220	0.420	0.020	0.020	0.560
11	ind	0.421	0.446	0.176	0	0.266	0.156	0.160	0.900	0.060	0	0.660	0.100
12	frd	0.250	0.286	0.226	0.545	0.60	0.423	0.320	0.200	0.280	0.360	0.960	0.220
13	ind	0.314	1.00	0.143	0	0.180	0.341	0.660	0.020	0.020	0	0.400	0.300
14	frd	0.141	0.833	0.393	0.333	0.588	0.381	0.180	0.200	0.220	0.320	1.00	0.480

として検定する。まず、正規性を Kolmogorov-Smirnov 検定を用いて検定する。Kolmogorov-Smirnov 検定の帰無仮説は、「母集団が正規分布である」である。結果を表 7 に示す。有意水準 5%としたとき、すべての場合において帰無仮説は棄却されない。よって、 P およびパーソナリティクラスタに分割した場合の f は正規分布ではないとはいえない。

次に、Welch の t 検定を用いてパーソナリティごとの分割が有意かどうか検証する。 t 検定の帰無仮説は、「2 群の母平均に差がない」である。結果を表 8 に示す。有意水準 5%としたとき、 S_N および S_F は帰無仮説が棄却される。また、有意水準を 10%とした場合、 S_{LO} の帰無仮説が棄却される。したがって、パーソナリティごとに分けることで、 S_N および S_F の識別精度が上がる。また、 S_{LO} の識別精

度が上がることが示唆される。その他の状態において、検定による有意差は見られなかった。

5.3 特徴分析

5.2 節で有意差のあるユーザ状態における足取りベクトル成分の特徴を考察する。主要な足取りベクトル成分の特徴を考察するために、各パーソナリティクラスタにおいて、変数重要度の高い足取りベクトル成分を抽出する。表 10 に各パーソナリティクラスタごとの RF によって算出された変数重要度の高い成分を降順に示す。表側の数字は順位を示し、R は右足、L は左足を示す。すべてのパーソナリティクラスタにおいて歩速 w_{v_1} , w_{v_2} , w_{v_3} が重要視されていることが分かる。また、 $c_p(ind)$ では他のパーソナリティクラスタと異なりおれ g_{dev} が 3 位および 4 位に入っ

表 6 パーソナリティクラスタに分割しない場合、分割した場合の f (有効数字 3 桁に四捨五入)

Table 6 F-measure without/with clustering.

k	cluster	f-measure without clustering						f-measure with clustering					
		S_N	S_{LB}	S_{LO}	S_T	S_A	S_F	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F
1	eg	0.359	0.422	0.491	0	0.662	0.119	0.235	0.031	0.348	0	0.478	0.500
2	ind	0.311	0.787	0	0.110	0.542	0.393	0.345	0.705	0.416	0.596	0.694	0.327
3	frd	0	0.390	0	0.034	0.597	0	0.260	0.301	0.350	0.296	0.718	0.206
4	ind	0.065	0.450	0.293	0.353	0.1	0.370	0.036	0.301	0.152	0	0.037	0.272
5	ind	0.120	0.024	0.146	0	0.531	0.099	0.286	0.045	0.343	0	0.298	0.231
6	eg	0.364	0.250	0	0	0.936	0.023	0.360	0.140	0	0	0.718	0.137
7	ind	0.226	0.632	0	0.014	0.487	0.187	0.340	0.690	0.712	0	0.535	0.384
8	frd	0.039	0.259	0.163	0.483	0.809	0.022	0.109	0.095	0.173	0.500	0.750	0.094
9	frd	0.182	0.184	0.145	0.065	0.551	0.093	0.155	0.094	0.145	0.100	0.667	0.202
10	eg	0.118	0.203	0.439	0.39	0	0.023	0.154	0.153	0.408	0.037	0.033	0.381
11	ind	0	0.406	0.039	0.347	0.529	0	0.232	0.596	0.090	0	0.379	0.122
12	frd	0.179	0.400	0.132	0.175	0.734	0.242	0.281	0.235	0.250	0.434	0.738	0.289
13	ind	0.030	0.074	0	0	0.312	0.128	0.426	0.039	0.035	0	0.248	0.319
14	frd	0.051	0.254	0.163	0.206	0.698	0.250	0.158	0.323	0.282	0.327	0.741	0.425

表 7 Kolmogorov-Smirnov 検定の p 値 (有効数字 3 桁に四捨五入)

Table 7 P-value in Kolmogorov-Smirnov test.

	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F
Divided	0.835	0.866	0.401	0.618	0.496	0.779
P	0.933	0.599	0.921	0.191	0.365	0.999

表 8 Welch の t 検定の p 値および t 値 (有効数字 3 桁に四捨五入)

Table 8 P-value and t-value in Welch's Two Sample t-test.

	S_N	S_{LB}	S_{LO}	S_T	S_A	S_F
p 値	0.044	0.408	0.080	0.915	0.743	0.007
t 値	2.12	-0.841	1.82	0.108	-0.332	2.91

ており、身長 h も上位 10 成分に含まれている。これらから、パーソナリティクラスタによっては足取りの特徴が現れる足取りベクトル成分が異なることが示唆される。

次に、抽出された成分において、5.2 節で有意差のあったユーザ状態での平均値・標準偏差を算出し、比較する。そして特徴のある成分を P と比較し、識別に影響のある成分を見つける。相関のある成分は似た特徴を示すと考えられるため、各パーソナリティクラスタにおいて表 9 に示した変数重要度の高い 10 成分を相関分析する。算出される相関値の絶対値が 0.8 以上の項目を除く足取りベクトル成分を抽出する。また、相関のある成分は変数重要度の最も高い項目を抽出する。抽出された成分において、ユーザ状態によって変化しない身長を除くぶれ g_{dev} 、歩速 w_{v_1} 、歩幅 $w_{w_5}(i)$ の平均値・標準偏差を算出する。各パーソナリティクラスタおよび P において算出された平均値・標準偏差を図 10、図 11、図 12 に示す。

5.2 節で有意差のあったユーザ状態について、無負荷である状態 S_N と比較し、差のある成分を見つける。その成分をクラスタリングしない P と比較し、考察する。パー

表 9 変数重要度上位 10 成分

Table 9 Top 10 important variables.

	$c_p(frd)$		$c_p(ind)$		$c_p(eg)$	
	L	w_{v_1}	L	w_{v_1}	L	w_{v_1}
1	L	w_{v_1}	L	w_{v_1}	L	w_{v_1}
2	R	w_{v_1}	R	w_{v_1}	R	w_{v_1}
3	L	w_{v_3}	L	g_{dev}	R	w_{v_2}
4	L	w_{v_2}	R	g_{dev}	R	w_{v_3}
5	R	w_{v_3}	R	w_{v_2}	L	w_{v_2}
6	R	w_{v_2}	L	w_{v_2}	L	w_{v_3}
7	L	$w_{w_5}(i)$	L	w_{v_3}	L	g_{dev}
8	R	g_{dev}	R	w_{v_3}	R	$w_{w_5}(i)$
9	R	$w_{w_5}(i)$	L	$w_{w_5}(i)$	R	g_{dev}
10	L	g_{dev}		h	R	w_t

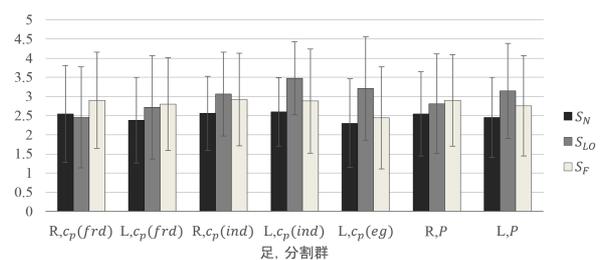


図 10 足取りベクトル g_{dev} の平均値・標準偏差
Fig. 10 Average and standard deviation of g_{dev} .

ソナリティクラスタ $c_p(frd)$ について以下が分かる。状態 S_{LO} 、 S_F に着目する。図 10 より、状態 S_F は状態 S_N よりぶれ g_{dev} が大きい。同様に左足において状態 S_{LO} は状態 S_N よりぶれ g_{dev} が大きい、右足は同程度である。これは右側のみ荷物を負荷したためであると考えられる。図 11、12 より、それぞれの歩速 w_{v_1} および歩幅 $w_{w_5}(i)$ は状態 S_N と同程度である。ここで、図 10 のぶれ g_{dev} について P と比較すると、 S_F と状態 S_{LO} 間の差が大きい。つ

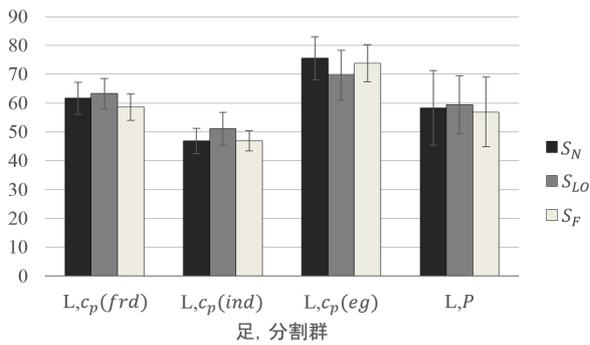


図 11 足取りベクトル w_{w_1} の平均値・標準偏差 (cm/s)
 Fig. 11 Average and standard deviation of w_{w_1} .

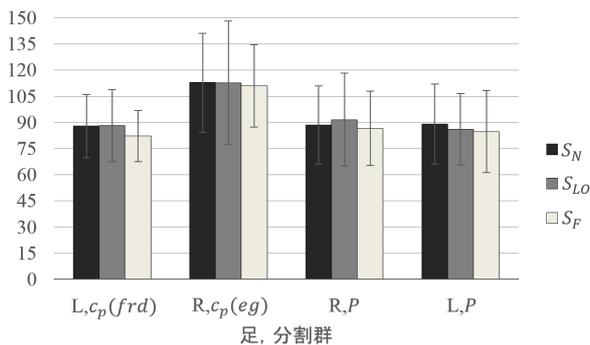


図 12 足取りベクトル $w_{w_5}(i)$ の平均値・標準偏差 (cm)
 Fig. 12 Average and standard deviation of $w_{w_5}(i)$.

まり、全ユーザと比較して、両手に荷物を持った場合と片手に荷物を持った場合でぶれ g_{dev} の差が大きい。したがって、状態 S_F , S_{LO} は、ぶれ g_{dev} が識別精度の増加や誤分類の減少に影響していると考えられる。

次に、パーソナリティクラスター $c_p(ind)$ について以下が分かる。状態 S_{LO} に着目する。図 10 より、状態 S_N よりぶれ g_{dev} が大きい。図 11 より、他のユーザ状態より歩速 w_{v_1} が大きい。ここで、図 10, 11 の各成分について P と比較すると、左足の状態 S_{LO} のぶれ g_{dev} が大きく、状態 S_{LO} の歩速 w_{v_1} が状態 S_N より大きい。つまり、全ユーザと比較して、片手荷物に対してぶれ g_{dev} が大きく、荷物を持ったさいに早足になる。したがって状態 S_{LO} は、ぶれ g_{dev} 、歩速 w_{v_1} が識別精度の増加や誤分類の減少に影響していると考えられる。また、状態 S_F に着目する。図 11 より、状態 S_N よりぶれ g_{dev} が大きい。図 11 より、状態 S_N と歩速 w_{v_1} が類似している。したがって状態 S_T , S_F は、歩速 w_{v_1} が識別精度の増加や誤分類の減少に影響していると考えられる。

最後に、パーソナリティクラスター $c_p(eg)$ について以下が分かる。状態 S_{LO} に着目する。図 10 より、状態 S_N よりぶれ g_{dev} が大きい。図 11 より歩速 w_{v_1} が小さい。ここで、図 10, 11 の各成分について P と比較すると、状態 S_N を含め、歩速 w_{v_1} が大きい。したがって、状態 S_{LO} は、ぶれ g_{dev} 、歩速 w_{v_1} が誤分類の減少に影響していると考えら

表 10 各パーソナリティクラスターでの特徴的な足取りベクトル成分
 Table 10 Characteristic variables in each cluster.

states cluster	S_{LO}			S_F		
	<i>frd</i>	<i>ind</i>	<i>eg</i>	<i>frd</i>	<i>ind</i>	<i>eg</i>
R, g_{dev}		*	/	*		/
L, g_{dev}	*	*	*	*		
L, w_{v_1}		*	*		*	
R, $w_{w_5}(i)$	/	/		/	/	*
L, $w_{w_5}(i)$	/	/	/	/	/	/

* means significant difference

れる。また、状態 S_F に着目する。図 10 から図 12 より、ぶれ、歩速、歩幅すべてが状態 S_N に類似している。したがって、状態 S_F は状態 S_N との識別が困難である。ここで、図 10 から図 12 の各成分について P と比較すると、状態 S_N を含め、歩速 w_{v_1} が大きい。つまり、普段から足が速く疲労した場合でも歩速が変化しない。したがって、状態 S_F は、歩速 w_{v_1} が誤分類の減少に影響していると考えられる。それぞれのパーソナリティクラスターに関して、影響の大きいと考えられる成分のまとめを表 10 に示す。以上から、それぞれのパーソナリティクラスターについて、ユーザ状態の識別に影響を与える足取りベクトル成分が異なることが示唆される。

5.4 パーソナリティと足取りの特徴

次に、パーソナリティとパーソナリティクラスターの関係性を考察する。YG 性格検査結果と図 10 から 12 より以下が分かる。

- 図 10 から図 12 において、 $c_p(eg)$ の状態 S_F は状態 S_N と類似している。つまり、のんきなユーザや客観的なユーザ、活発さが中程度のユーザは疲労が足取りに表れにくいと考えられる。
- 図 11 において、 $c_p(frd)$ および $c_p(eg)$ の歩速は $c_p(ind)$ より速いことから、人に対して開放的なユーザや消極的なユーザは早足であると考えられる。
- 図 11 において、 $c_p(ind)$ の歩速は他のパーソナリティクラスターより遅いことから、主観客観に偏りのないユーザは、足が遅いと考えられる。

以上から足取りで分類したパーソナリティクラスターにパーソナリティが現れることが示唆される。

5.5 まとめ

以上から、各パーソナリティクラスターおよび各ユーザ状態において、識別に影響を与える足取りベクトル成分が異なる。これはパーソナリティごとに足取りが違うことに起因する。それゆえ、パーソナリティを考慮しない、つまりクラスタリングしない場合、個人差の影響が大きくでてしまい、識別精度が減少する。よって、ユーザのパーソナリティごとに分類、つまり足取りでクラスタリングすること

で、ユーザ状態の識別精度が向上する。一方、表 6 における各識別結果である f の平均値から、 $c_p(eg)$ はクラスタリングしない方が精度が高い。今回、 $c_p(eg)$ に分類されたユーザ数は他のパーソナリティクラスと比べ少ないため、ユーザのサンプル数が不十分であったことが考えられる。

6. 実環境への適用可能性

本論文では、2章で関連研究のコスト、識別能力について問題点をあげた。コストに関して、リーダは2,000円弱、タグは1枚あたり数十円と安価である。また、タグの配置のみでシステムの利用範囲が拡大できるため、拡張性が高い。識別能力に関して、本論文では、RFIDのみで複数のユーザ状態およびパーソナリティを推定できることを示した。本手法をショッピングモール内に適用することで、顧客の性格や状態を把握し、適切なおもてなしを顧客に適した形で提供することができる。ショッピングモール側が観光客にアンケートのような着脱式のリーダを貸し出し、人通りの多い通路にタグシートを設置する。ショッピングモール内の個々の店舗もタグシートを設置することで、3章で述べたような恩恵を受けることができる。タグは、比較的安価であり、検出は一定区間だけあればよいので、容易にシステムを実装できる。今回の被験者は20代男女だったが、歩行特徴は20代～60代で変わらないという研究がある[39]。また、訪日外国人の世代別の割合は、30代男性が17.7%で最も大きく、次いで20代女性、40代男性、20代男性である[4]。したがって、多くの訪日外国人観光客への適用が可能であることが示唆される。

7. おわりに

本論文では、高品質なおもてなしの提供のために、RFIDによって取得されたユーザの足取りの特徴から、パーソナリティやユーザ状態を推定する手法を提案した。実験では、足取りの特徴が似たユーザ同士にクラスタ分類することで、各クラスタにパーソナリティが現れることが確認された。また、クラスタごとに機械学習することで、クラスタ分類しない場合と比較して、ユーザ状態の識別精度が向上することが示唆された。また、パーソナリティクラスに分類することで、ユーザ状態の識別精度が向上するユーザ状態があることが確認された。加えて、パーソナリティごとにおいて、ユーザ状態ごとにRFIDシステムで取得される特徴が異なることが示唆された。今後は、今回実験したユーザ状態以外にも想定されるユーザ状態を複数のユーザにおいて検証する。また、タグシートの最適な配置や材質や設置方法および、おもてなしの提供頻度や提供方法などの具体的なサービスを考察する。

参考文献

- [1] 日本政府観光局：国籍/月別 訪日外客数（2003年～2015年），日本政府観光局（online），入手先（http://www.jnto.go.jp/jpn/reference/tourism_data/pdf/2013_15_tourists.pdf）（参照 2015-09-05）。
- [2] 国土交通省観光庁：観光立国推進戦略会議，国土交通省観光庁（online），入手先（<http://www.mlit.go.jp/kankochou/iinkai/senryaku.html>）（参照 2015-09-05）。
- [3] 首相官邸：観光立国推進戦略会議，首相官邸（online），入手先（<http://www.kantei.go.jp/jp/singi/kanko2/suisin/index.html>）（参照 2015-09-05）。
- [4] 観光庁：訪日外国人の消費動向 平成25年 年次報告書，観光庁（online），入手先（<http://www.mlit.go.jp/common/001032143.pdf>）（参照 2015-09-05）。
- [5] 三菱電機株式会社：自動車向け「簡単操作インターフェース」を開発，三菱電機株式会社（online），入手先（<http://www.mitsubishielectric.co.jp/news/2014/pdf/0210.pdf>）（参照 2015-09-05）。
- [6] Ikeda, T., Chigodo, Y., Kishino, F., et al.: A Method to Recognize 3D Shapes of Moving Targets based on Integration of Inclined 2D Range Scans, *IEEE International Conference on Robotics and Automation*, pp.1237–1240 (2011).
- [7] Qi, Y., Huang, G. and Wang, Y.: Carrying Object Detection and Tracking Based On Body Main Axis, *IEEE International Conference on Wavelet Analysis and Pattern Recognition*, pp.1237–1240 (2007).
- [8] Yonekawa, K., Yonezawa, T., Nakazawa, J., et al.: FASH: Detecting Tiredness of Walking People Using Pressure Sensors, *Mobile and Ubiquitous Systems: Networking & Services*, pp.1–6 (2009).
- [9] Arif, M., Ohtaki, Y., Nagatomi, R., et al.: Analysis of the Effect of Fatigue in Walking Gait Stability, *IEEE International Symposium on Micromechatronics and Science*, pp.253–258 (2002).
- [10] Arif, M., Ohtaki, Y., Nagatomi, R., et al.: Analysis of the effect of fatigue on walking gait using acceleration sensor placed on the waist, *International Journal of Engineering Intelligent Systems*, pp.93–103 (2010).
- [11] Music, J., Stancic, I. and Zanchi, V.: Is it Possible to Detect Mobile Phone User's Attention Based on Accelerometer Measurement of Gait Pattern?, *IEEE Symposium on Computers and Communications*, pp.522–527 (2013).
- [12] Thepvilojanapong, N., Yakiyama, Y., Mihirogi, O., et al.: Evaluating People's Attention in the Real World, *ICROS-SICE International Joint Conference*, pp.3702–3709 (2009).
- [13] Clippingdale, S., Okada, M. and Takahashi, M.: Level-of-Interest Estimation for Personalized TV Program Recommendation, *IEEE International Conference on Consumer Electronics*, pp.11–14 (2013).
- [14] Naemura, M., Clippingdale, S., Takahashi, M., et al.: Real-time LDCRF-based method for inferring TV viewer interest, *Humaine Association Conference on Affective Computing and Intelligent Interaction*, pp.485–491 (2013).
- [15] Roshchina, A., Cardiff, J. and Rosso, P.: User Profile Construction in the TWIN Personality-based Recommender System, *Workshop on Sentiment Analysis where AI meets Psychology SAAIP, 5th International Joint Conference on Natural Language Processing*, pp.1–7 (2011).

- [16] Roshchina, A., Cardiff, J. and Rosso, P.: A Comparative Evaluation of Personality Estimation Algorithms for the TWIN Recommender System, *Proc. 3rd International Workshop on Search and Mining User-Generated Contents*, pp.11–18 (2011).
- [17] Minamikawa, A. and Yokoyama, H.: Blog Tells What Kind of Personality You Have: Egogram Estimation from Japanese Weblog, *Proc. ACM 2011 Conference on Computer Supported Cooperative Work*, pp.217–220 (2011).
- [18] 杉原太郎, 藤波 努, 中川健一: カメラとモニタ導入に伴うグループホーム介護者の負担感に関する研究, 電子情報通信学会技術研究報告, pp.73–78 (2008).
- [19] 元重朋子, 吉野公三, 荒木 勉ほか: 疲労が歩行と心拍に与える影響の解析, 日本機械学会第13回バイオエンジニアリング学術講演会・講演論文集, pp.59–60 (2002).
- [20] 小澤春香, 松崎 崇, 中山惟人ほか: 健常者のトレッドミル歩行における荷物運搬課題の相違が身体反応へおおよぼす影響, 理学療法科学学会, pp.909–912 (2010).
- [21] 横山真由子: 片側荷物不可歩行時の Kinematics と Kinetics, 運動学習研究会報告集, Vol.14, pp.54–57 (2014).
- [22] Thoresen, J., Vuong, Q. and Atkinson, A.: First impressions: Gait Cues Drives Reliable Trait Judgments, *Cognition*, Vol.124, No.3, pp.261–271 (2012).
- [23] Li, F., Zhao, C., Gong, J., et al.: A Reliable and Accurate Indoor Localization Method Using Phone Inertial Sensors, *Proc. 2012 ACM Conference on Ubiquitous Computing*, pp.421–430 (2012).
- [24] Yu, Y., He, J., Wang, Q., et al.: A Query-driven Indoor Location System based on Smartphone, *IEEE Workshop on Enabling Technologies for Smartphone and Internet of Things*, pp.25–29 (2012).
- [25] Mirowski, P., Ho, T., Yi, S., et al.: Signal SLAM: Simultaneous Localization and Mapping with Mixed WiFi, Bluetooth, LTE and Magnetic Signals, *International Conference on Indoor Positioning and Indoor Navigation*, pp.1–10 (2013).
- [26] Ibara, K., Kanetsuna, K. and Hirakawa, M.: Identifying Individuals' Footsteps Walking on a Floor Sensor Device, *Proceeding of the Active Media Technology, Lecture Notes in Computer Science*, Vol.8210, pp.56–63, Springer (2013).
- [27] Oikawa, M., Tanijiri, N. and Hirakawa, M.: Estimation of Lower Body Motion during Walking on a Floor Sensor Device, *ICIC Express Letters*, Vol.6, No.12, pp.3027–3031 (2012).
- [28] Aminian, K., Dadashi, F., Mariani, B., et al.: Gait Analysis Using Shoe-worn Inertial Sensors: How is Foot Clearance Related to Walking Speed?, *Proc. 2014 ACM Conference on Ubiquitous Computing*, pp.481–485 (2014).
- [29] Choi, B., Lee, J. and Lee, J.: Localization and Map-building of Mobile Robot Based on RFID Sensor Fusion System, *IEEE International Conference on Industrial Informatics*, pp.412–417 (2008).
- [30] Choi, B., Lee, J., Lee, J., et al.: A Hierarchical Algorithm for Indoor Mobile Robot Localization Using RFID Sensor Fusion, *IEEE Transactions on Industrial Electronics*, Vol.58, No.6, pp.2226–2235 (2011).
- [31] Wang, H., Bauer, G., Kirsch, Fabian., et al.: Hybrid RFID System-based Pedestrian Localization: A Case Study, *10th Workshop on Positioning, Navigation and Communication*, pp.1–6 (2013).
- [32] Weinstein, R.: *RFID: A technical overview and its application to the enterprise*, IT Professional, Vol.7, No.3, pp.27–33 (2005).
- [33] Perry, J. and Burnfield, J.: *Gait Analysis: Normal and Pathological Function*, Chapter 20, Slack Inc. (2010).
- [34] Ward, J.H.: Hierarchical grouping to optimize an objective function, *Journal of the American Statistical Association*, Vol.58, No.301, pp.236–244 (1963).
- [35] 森長 誠, 松井孝典, 月岡秀文: 音響情報を用いた軍用機種種の識別, 人工知能学会全国大会論文集, pp.1–2 (2014).
- [36] Breiman, L.: Random Forests, *Journal of Machine Learning*, Vol.45, pp.5–32 (2001).
- [37] 岡堂哲雄: 心理検査学: 心理アセスメントの基本, 垣内出版, pp.269–281 (1975).
- [38] Karvonen, M., Kentala, E. and Mustala, O.: The effects of training on heart rate; A longitudinal study., *Annales Medicinæ Experimentalis et Biologiae Fenniae*, Vol.35, No.3, pp.307–315 (1957).
- [39] Jin, B., Thu, T., Baek, E., et al.: Walking-Age Analyzer for Healthcare Applications, *IEEE Journal of Biomedical and Health Informatics*, pp.1034–1042 (2014).



植村 喜弘 (学生会員)

2015年立命館大学情報理工学部情報システム学科卒業。現在、同大学大学院情報理工学研究科情報理工学専攻博士前期課程在籍中。



梶原 祐輔 (正会員)

2009年東京電機大学理工学部情報システム工学科卒業。2011年金沢大学大学院自然科学研究科博士前期課程修了。2013年金沢大学大学院自然科学研究科博士後期課程修了。同年立命館大学情報理工学部助教、現在に至る。

医用画像処理やヒューマンインタフェースに関する研究に従事。



島川 博光 (正会員)

京都大学大学院博士後期課程修了。博士(工学)。三菱電機(株)にて実時間制御システムの研究に従事。2002年より立命館大学教授、現在に至る。データ工学, 教育工学の研究に従事。IEEE, ACM 各会員。