

スマートフォンの複数センサを用いた歩容識別に対する様々な状況の比較検討 Comparison of Various States for Gait Recognition Using Smart Phone Sensors

渡邊 裕司[†]
Yuji Watanabe

1. まえがき

スマートフォン, タブレット, ウェアラブルなどモバイル端末には多くの重要な個人情報が含まれるため, 個人認証の必要性はかなり高い. PIN やパスワード認証, 指紋など生体的特徴による認証が使用開始時に一般的に行われるのに対して, 行動的特徴による認証は継続的かつ暗黙的に(つまりユーザを煩わせることなく)認証できる.

そこで我々は, スマートフォンに内蔵されたタッチセンサや加速度センサなど複数センサから, 使用開始時以外のタッチ操作時や歩行時などでの各ユーザの操作や行動の特徴を抽出して個人認証する研究を進めている[1-5]. 本稿はスマートフォンの加速度センサを用いて歩行時の特徴から認証する歩容認証[4, 5]の続報である. 先行研究[5]では, 加速度センサに加えてジャイロスコープや磁力センサによってスマートフォンの傾きなどを検出し, 世界座標系での加速度も取得できるように研究[4]で開発した iOS 上のアプリケーション(以下アプリと略す)を改良した. そして, 被験者に対してポケットに入れるだけでなくタッチ操作や通話をしながら歩くという三つの保持状況下で加速度や傾きなどを改良アプリで取得した. 軸補正された加速度から 43 個の特徴を抽出し, いくつかの分類アルゴリズムを用いて歩容認証を試みた. その結果, タッチ操作をしながらの状況で本人拒否が多発するもの, ポケットに入れた状況では 1.3%の他人受入率と 2.3%の本人拒否率を達成した. しかし, 被験者 4 名に対する予備実験の段階であった. また, 各被験者に対して 1 回だけの実験であり, 例えばポケットの位置が異なる場合, 別の日に追加実験を行った場合なども調べていなかった.

本稿では, まず被験者を増やしつつ, 約 1 か月後に記録されたデータも追加しながら歩容の識別を行う. また, 被験者 1 名に対してポケットの位置や持ち手や履物を変えた様々な状況においてデータを取得して歩行状況の認識を試みた結果についても報告する.

2. 関連研究

ウェアラブルセンサによる歩容認証研究は, 2005 年に Ailisto ら[6]によって最初に行われ, Gafurov らの研究[7]などによって引き続かれた. これらの研究では, 歩行時における尻や腕や足首などの加速度を計測するために, 専用の高品質な加速度計を装着させていた. それに対して, スマートフォンには加速度センサも通常装備されていることから, 近年スマートフォンを用いた歩容認証も行われている[8-11]. Kwapisz らの研究[8]では, 36 人の被験者に対して, Android 端末をズボンのポケットに入れてもらい, 歩行・走行・階段昇降時の 3 軸加速度データを記録した. そして加速度データから 43 個の特徴を抽出し, 決定木とニュー

ラルネットワークを用いて識別と認証を行い, 歩行と走行時には 90%以上の識別精度を得ている. Nickel ら[9]は, ベルトにつけられたポーチの中に Android 端末を入れて, 被験者 48 名に対して二日に分けて歩行時の加速度を取得した. この加速度に対して隠れマルコフモデル(Hidden Markov Model: HMM)を適用したところ, 動的時間伸縮法(Dynamic Time Warping: DTW)の約 20%と比較して, 約 10%の等誤り率を達成している. Gait-ID[10]では, 端末画面を外側に向けて縦向きに右ポケットに入れて, 2 種類の速度の異なる歩行を 36 人の被験者にしてもらい, 歩行速度に依存しない認証方法が提案された.

これらの研究では, センサを特定の場所に装着したり, スマートフォンをポケットに入れたり, ほぼ同じ状況下でのデータ取得であった. 実際には, スマートフォンで通話やタッチ操作をしながら歩く状況もあり, その場合にはスマートフォンの向きなども考慮する必要がある. 最近 Primo ら[11]が同様の指摘を行い, Google Nexus を両ポケットに入れた場合と両手に持った場合で比較している. また, Ngo ら[12]もセンサ方向の不一致を解決する方法を提案し, その有効性を示しているが, スマートフォンではなく 4 個の専用センサを用いてデータを取得している.

3. 加速度に基づく歩容識別

3.1 歩容記録アプリ

まず本研究でも使用する先行研究[5]で改良した歩容記録アプリについて説明する. iOS イベント処理ガイド[13]によると, Core Motion フレームワークを使って加速度センサ, ジャイロスコープ, 磁力センサの生のデータにアクセスできる. そして Core Motion の CMDeviceMotion クラスにより, センサ融合アルゴリズムが生データを処理して, 端末の姿勢, 重力の方向, 重力を除くユーザが端末に与えた加速度など加工したデータも取得可能である. さらに, センサ開始時に特別な初期化方法があり, 例えば定数 CMAttitudeReferenceFrameXMagneticNorthZVertical によって, X 軸を水平面上の磁北とし, Z 軸を鉛直とすることもできる. 換言すれば, スマートフォン上の座標系(X 軸が画面の横方向, Y 軸が画面の縦方向, Z 軸が画面の垂直方向)から世界座標系に自動的に変換されて, スマートフォンの向きに依存しないデータを取得できる. 本アプリでは, この CMDeviceMotion クラスと上記の初期化方法を用いて, 以下のデータを時刻とともに記録する.

- 重力成分 (単位は G)
- 重力成分を除いて軸を補正されたユーザの行動による加速度成分 (単位は G)
- 各軸の回転速度 (単位はラジアン/秒)
- 各軸の磁界 (単位はマイクロテスラ)

[†]名古屋市立大学システム自然科学研究科, Graduate School of Natural Sciences, Nagoya City University

- ロールとピッチとヨー (単位はラジアン)

なお、Android 端末に対するアプリ開発も現在進めているが、端末座標系から世界座標系への座標変換を用意する必要がある。例えば、太田らの手法[14]は、Android 端末の加速度・ジャイロ・地磁気を用いて座標変換を行い、さらにカルマンフィルタを用いて誤差補正を行っている。

データ取得の間隔に関しては、既存研究[8]では 50ms のサンプリング周期つまり 1 秒間に約 20 個の各軸の加速度データを計測しているが、Nickel らの研究[9]では毎秒 200 個のデータを取得している。iOS イベント処理ガイドには最短で 10ms 間隔 (100Hz の更新レート) まで設定できるとあるため、本アプリでは毎秒約 100 個のデータを記録する。

3.2 加速度の前処理

記録されたデータから「重力成分を除いて軸を補正されたユーザの行動による加速度成分」に着目する。各実験において各被験者は約 1 分かけて約 50 m の廊下を一往復する。ある被験者がスマートフォンをポケットに入れて歩いた時の世界座標系における 3 軸のユーザ生成加速度の例を図 1 に示す。同図において、開始から約 3 秒までは被験者がスマートフォンをポケットに入れるところであり、約 5 秒後から歩き始めている。このように、まだ歩いていない期間は前処理によって削除する。同様に進行方向を変えている前後の期間も前処理によって削除する。




図 1 世界座標系における 3 軸のユーザ生成加速度の例

3.3 特徴抽出

前処理された加速度の時系列データに対して、オーバーラップを許さないサイズ 300 のウィンドウに分割する。これは約 3 秒に相当する。毎秒 20 個の取得間隔であった Kwapisz らの研究[8]ではウィンドウサイズを 200 としていたが、これは 10 秒に相当し、認証に時間をかけすぎている。それに対して、Nickel らの研究[9]は 3 秒に分割しているため、本研究ではこれに合わせてサイズを 300 にする。なお、Gait-ID[10]で行われたより短い 1 秒サイズも今後検討すべきである。

各ウィンドウ内の各軸 300 個のデータから抽出する特徴は、先行研究[4, 5]や既存研究[8]と同様に、以下の 43 個とする。ここで x_i , y_i , z_i はウィンドウ内の i 番目の各軸の加速度を表す。

- 平均値 (3 軸) : $\bar{x} = \sum_{i=1}^{300} x_i / 300$
- 標準偏差 (3 軸) : $\sqrt{\sum_{i=1}^{300} (x_i - \bar{x})^2 / 300}$

- 平均偏差 (3 軸) : $\sum_{i=1}^{300} |x_i - \bar{x}| / 300$
- 平均合成加速度 : $\sum_{i=1}^{300} \sqrt{x_i^2 + y_i^2 + z_i^2} / 300$
- ピーク間の時間 (3 軸) : 加速度には波形の繰り返しが見られるため、ピーク間の時間を求める。実際には、300 個のデータ中の最大値を 1 個目のピーク、2 番目に大きい値を 2 個目のピークとし、3 個のピークを見つける。そして連続したピーク間の時間を求めて平均する。
- ビン分布 (3 軸×10 個) : 300 個のデータ中の最大値から最小値を引くことで範囲を求め、その範囲を 10 個の等しい大きさのビンに分割する。300 個のデータそれぞれがどのビンに入るかを数え、各ビンのデータの割合を求める。

なお、加速度のような時系列データに対しては、Nickel らの研究[9]のように HMM や DTW を直接適用する別の方法もある。生データから自動で特徴抽出をするディープラーニング[15]も有望なアプローチである。しかし、これらの技法は、今後スマートフォン上で実装する際に多くの計算リソースを必要とするかもしれない。これらの技法との比較は今後の課題である。

3.4 識別処理

上記の 43 個の特徴に対して分類アルゴリズムを適用し、どの被験者かまたはどの歩行状況かの識別を試みる (もちろん本人か他人かの認証も可能である)。分類アルゴリズムには Weka のデータマイニングソフト[16]を使う。Kwapisz らの研究[8]では決定木 J48 とニューラルネットワーク (Neural Network: NN) の二つであったのに対して、先行研究[4]で Weka の全アルゴリズムを試し、放射基底関数 (Radial Basis Function: RBF) が最も結果が良いことを確認した。続く研究[5]では、ベイジアンネットワーク (Bayesian Network: BN) とランダムフォレスト (Random Forest: RF) でも良い結果が得られたが、決定木 J48 はどの場合でも最悪であった。そこで本研究では、四つのアルゴリズム (BN, NN, RBF, RF) を使用する。各アルゴリズムに対して、Weka の設定はデフォルトのままとし、10 分割交差検証を用いる。評価指標として、正しく識別された割合である「識別率」を求める。

4. 実験結果

4.1 実験方法

本研究では 2 種類の実験を行った。第一の実験では、被験者を増やしつつ、約 1 か月後に記録されたデータも追加しながら被験者を識別する。第二の実験では、被験者 1 名に対してポケットの位置や持ち手や履物を変えた様々な状況において歩行状況を識別する。第一と第二の実験の識別対象は、被験者と歩行状況で異なる。各実験の各被験者に対して、歩容記録アプリを搭載した iPhone 5 32GB を保持して、約 50m の長さの廊下を 1 往復歩いてもらい (時間は約 1 分)、3.1 節で挙げたデータを記録する。実験後に iPhone を回収して、iTunes 経由でデータをパソコンに取得し、パソコン上で前処理、特徴抽出、識別処理を行った。

第一の実験では、被験者 8 名にある日に参加してもらい、その内 4 名の被験者には約 1 か月後の別の日にも参加して

もらった（本稿執筆時点では被験者が少ないが、現在より多くの被験者で実験中である）。そして、先行研究[5]と同様に、各被験者に対して iPhone を以下の三つの状況で保持してもらった。

1. ポケットに入れて
2. 電話しながら（実際にはスマートフォンを耳に当てて通話はしない電話のふり）
3. 画面を見ながら（実際にはスマートフォンを操作せずに画面を見ているだけ）

第二の実験では、同一の日に被験者 1 名に対して表 1 に示す 9 個の異なる歩行状況を試みた。9 個の歩行状況は、まず上述の三つの保持状況に分けられる。そして状況 1-1 から 1-4 まではスマートフォンの位置が異なり、状況 1-5 では履物がスリッパでなく靴である。また状況 2-1 と 3-1 では右手で、状況 2-2 と 3-2 では左手で保持する。

表 1 被験者 1 名に対する 9 個の異なる歩行状況

状況	保持	スマホの位置	履物
1-1	ポケット	ズボンの右前ポケット	スリッパ
1-2	ポケット	ズボンの左前ポケット	スリッパ
1-3	ポケット	ズボンの右後ポケット	スリッパ
1-4	ポケット	シャツの左前胸ポケット	スリッパ
1-5	ポケット	ズボンの右前ポケット	靴
2-1	電話	右手	スリッパ
2-2	電話	左手	スリッパ
3-1	見ながら	右手	スリッパ
3-2	見ながら	左手	スリッパ

4.2 識別結果

第一の実験では、三つの保持状況それぞれに対して分類アルゴリズムを用いて被験者を識別した。先行研究[5]において三つの保持状況の加速度が同一被験者で大きく異なり、保持状況が異なる被験者を同一と識別しにくいことが確認されたため、保持状況ごとに分けて被験者を識別する。ポケットに入れた状況 1 では足の振動が直接スマートフォンに伝わるのに対して、スマートフォンを手を持っている状況 2 と 3 では手によってその振動を緩和しているためであると考えられる。なお、被験者識別の前にスマートフォンの傾きなどから自動的に保持状況を推定する方法については、上坂らの手法[17]を参考にしながら検討中である。

まず、二つの分類アルゴリズム ((a) Bayesian Network, (b) Radial Basis Function) を用いた時の識別すべき被験者の数に対する被験者の識別率の推移を図 2 に示す。なお、残りの二つのアルゴリズム (Neural Network と Random Forest) も類似の傾向を示した。一般的な問題として、生体認証において識別すべき人数が増えれば、類似の特徴を持つ可能性が増えるため性能は悪化する。同図からポケットに入れた状況 1 ではまだ被験者数の増加による影響は受けていないが、スマートフォンを手を持っている状況 2 と 3 では少ない被験者数つまり 6 人だけで識別率の悪化が始まっている。図 3 のグラフは、二つの保持状況 ((a)ポケットに入れ

た状況 1, (b)画面を見ながらの状況 3) 下での被験者 4 名の Z 軸方向（地面から鉛直方向）の加速度を重ねたものである。見やすくするために生の加速度データにローパスフィルタを適用した。図 3(a)の状況 1 では、被験者 A の振動は激しい一方で被験者 B の波形はなだらかなであるなど各被験者に対して加速度の波形に相違が確認される。これが状況 1 での良い識別に至った理由であるといえる。一方、図 3(b)の状況 3 では被験者 4 名の加速度が類似している。これが状況 3 での識別が悪化した理由であると予想される。

次に、約 1 か月後の別の日に被験者 4 名に対して記録された加速度データを追加した場合としない場合の四つの分類アルゴリズムによる識別率を表 2 に示す。同表において“状況 1”は、被験者 8 名それぞれがスマートフォンをポケットに入れて歩いたある一日に記録されたデータだけを用いることを意味する。一方、“状況 1+追加”は同じ被験者 4 名に対して別の日に記録されたデータも追加することを表す。異なる日の追加データは、被験者の歩容の違いにつながるかもしれない、識別率の低下が予想された。実際に表 2 の状況 1 と 2 においては、予想通りデータ追加によって識別率の低下を招いている。しかし、興味深いことに状況 3 においては逆に識別率の改善が確認される。改善の理由は不明であり、より多くの被験者のデータを取得してより詳細に解析する必要がある。

最後に第二の実験の結果を示す。表 3 は、被験者 1 名の 9 個の異なる歩行状況に対する四つの分類アルゴリズムによる状況の識別率である。結果から 9 個の歩行状況をどの分類アルゴリズムでも 9 割以上識別できていることが分かる。さらに、三つの保持状況の大まかな分類に対しては、より高い識別率を達成している。しかし、1 回の実験だけであり、第一の実験と同様に別の日に同じ状況で取得した追加データも用いた性能評価が必要である。

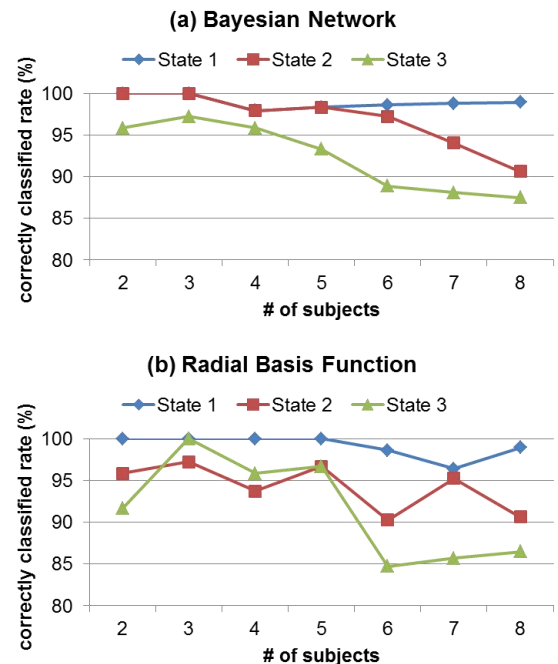


図 2 二つの分類アルゴリズム ((a) Bayesian Network, (b) Radial Basis Function) を用いた時の識別すべき被験者の数に対する被験者の識別率 (%)




図3 二つの保持状況 ((a)ポケットに入れた状況1, (b)画面を見ながらの状況3) 下での被験者4名のZ軸方向の加速度(ローパスフィルタを適用)

表2 別の日に被験者4名に対して記録された加速度データを追加した場合としなかった場合の四つの分類アルゴリズム (BN: Bayesian Network, NN: Neural Network, RBF: Radial Basis Function, RF: Random Forest) による被験者の識別率 (%)

状況	BN	NN	RBF	RF
状況1	98.96	97.92	98.96	96.88
状況1+追加	97.22	97.92	97.92	93.75
状況2	90.63	90.63	90.63	91.67
状況2+追加	86.11	88.89	86.11	81.25
状況3	87.50	87.50	86.46	83.33
状況3+追加	88.89	86.81	91.67	87.50

表3 被験者1名の9個の異なる歩行状況に対する四つの分類アルゴリズムによる状況の識別率 (%)

状況	BN	NN	RBF	RF
9個の状況	94.44	93.52	91.67	93.52
三つの保持状況	96.30	99.07	98.14	98.14

5. あとがき

本報告では、被験者を増やしつつ別の日に記録されたデータも追加しながら被験者の識別を行った。結果からスマートフォンをポケット入れた状況では識別人数の影響を受けにくいものの、手に保持した状況では少ない人数で識別率の悪化を確認した。また別の日のデータを追加した場合、保持状況に応じて異なる影響が見られた。さらに被験者1名に対してポケットの位置や持ち手や履物を変えた様々な状況に対して歩行状況の識別も行った。今後は被験者をよ

り増やして歩容データを取得するとともに、歩行状況を推定した上で被験者を識別する必要がある。

参考文献

- [1] 渡邊裕司, 市川俊太, “スマートフォンにおけるタッチ操作の特徴を用いた継続的な個人識別システムの検討”, コンピュータセキュリティシンポジウム, pp.797-804 (2012).
- [2] 藤田奨, 渡邊裕司, “Android 端末におけるタッチ操作の特徴を用いた個人認証に向けたアプリケーションの開発”, コンピュータセキュリティシンポジウム, pp.688-694 (2013).
- [3] 渡邊裕司, “Android 端末上のタッチ操作に基づく個人認証に対する操作特徴の比較”, コンピュータセキュリティシンポジウム, pp.1015-1022 (2014).
- [4] 彭龍, 渡邊裕司, “スマートフォン加速度センサを用いた歩行時の認証に関する一考察”, コンピュータセキュリティシンポジウム, pp.695-699 (2013).
- [5] Y. Watanabe, “Influence of Holding Smart Phone for Acceleration-based Gait Authentication,” Proc. of IEEE 2014 International Conference on Emerging Security Technologies (EST), pp.30-33 (2014).
- [6] H. J. Ailisto, M. Lindholm, J. Mäntyjärvi, E. Vildjiounaite, and S.-M. Mäkelä, “Identifying people from gait pattern with accelerometers,” Biometric Technology for Human Identification II, 5779(1), pp.7-14 (2005).
- [7] D. Gafurov, K. Helkala, and T. Sondrol, “Biometric Gait Authentication Using Accelerometer Sensor,” Journal of Computers, 1(7), pp.51-59 (2006).
- [8] J. R. Kwapisz, G. M. Weiss, and S. A. Moore, “Cell Phone-Based Biometric Identification,” Proc. of the 4th IEEE International Conference on Biometrics: Theory Applications and Systems, pp.1-7 (2010).
- [9] C. Nickel, C. Busch, S. Rangarajan, and M. Mobius, “Using Hidden Markov Models for Accelerometer-Based Biometric Gait Recognition,” IEEE 7th International Colloquium on Signal Processing and its Applications (CSPA), pp.58-63 (2011).
- [10] F. Juefei-Xu, C. Bhagavatula, A. Jaech, U. Prasad, and M. Savvides, “Gait-ID on the Move: Pace Independent Human Identification Using Cell Phone Accelerometer Dynamics,” IEEE 5th International Conference on Biometrics: Theory, Applications and Systems, pp.8-15 (2012).
- [11] A. Primo, V. V. Phoha, R. Kumar, and A. Serwadda, “Context-Aware Active Authentication Using Smartphone Accelerometer Measurements,” The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, pp. 98-105 (2014).
- [12] T. T. Ngo, Y. Makihara, H. Nagahara, Y. Mukaigawa, and Y. Yagi, “Orientation-Compensative Signal Registration for Owner Authentication Using an Accelerometer,” IEICE Transactions on Information and Systems, E97-D(3), pp.541-553 (2014).
- [13] iOS イベント処理ガイド 2013/01/28, <https://developer.apple.com/jp/devcenter/ios/library/documentation/EventHandlingiPhoneOS.pdf>
- [14] 太田麗二郎, 廣津登志夫, “手に保持された端末の慣性センサ・ジャイロセンサを用いた歩行者移動状態推定及び移動経路推定”, 情報処理学会第76回全国大会, 3, pp.171-172 (2014).
- [15] G. E. Hinton and R. Salakhutdinov, “Reducing the dimensionality of data with neural networks,” Science, 313(5786), pp.504-507 (2006).
- [16] I. Witten and E. Frank, “Data Mining: Practical Machine Learning Tools and Techniques,” Morgan Kaufmann Publishers, (2005).
- [17] 上坂大輔, 村松茂雄, 岩本健嗣, 横山浩之, “手に保持されたセンサを用いた歩行者向けデッドレコニング手法の提案”, 情報処理学会論文誌 52(2), pp.558-570 (2011).