

LSTMによる加速度に基づく個人推定

高橋良颯¹ 中村鴻介¹ 神山剛² 小口正人³ 山口実靖¹

概要: スマートフォンの加速度センサからえられた加速度データを深層学習(Deep Neural Network)を用いて解析し、スマートフォンの保持者を推定する手法が提案されている。ただし、当該手法は各時刻に得られた加速度データをソートし DNN に入力する方法をとっており、時系列データである加速度データ列の時間的特徴を考慮できない課題があり、正答率も 8 割強にとどまっている。

本稿では、加速度データを LSTM(Long short-term memory)を用いて解析し、保持者を推定する手法を 2 つ提案する。一つは、事前データを LSTM により学習し推定対象データを分類する手法であり、最も確率が高いと出力されたユーザを推定結果とする。もう一つは、出力確率が閾値以下である場合は推定結果を不明として false positive の発生確率を抑える手法である。そして、実ユーザ 5 人による評価実験の結果を示し、高い精度でユーザを推定できることを示す。

キーワード: 加速度センサ, 機械学習, LSTM, 個人推定

1. はじめに

近年、センサーデバイスと機械学習や深層学習を用いた様々な研究が行われており、一例としてセンサーデバイスから得られた情報を基に人間の動きを解析するというものがある[1][2]。

本研究では、スマートフォンの加速度センサーから得られた 3 軸加速度情報を解析し所有している個人を推定することに取り組む。本取り組みの推定により、使用ユーザの推定に基づく使用方法の推薦やサポートによるユーザエクスペリエンスの向上、歩行によるユーザ認証と入館管理の実現、正規ユーザ以外の保持の検出による盗難検出などの機能や応用が実現できると期待できる。ユーザのスマートフォン使用状況としては、本稿では推定を行いやすい歩きながらスマートフォンを操作している状況（以下、歩きスマホと呼ぶ）を用いる。ただし、本研究における取組はこの使用状況に強く依存するものではなく、他の使用状況への適用も可能であると我々は考えている。これまでに加速度データを DNN(Deep Neural Network)で解析しユーザを推定する手法[3]が提案されており、本稿では加速度を時系列データとみなしリカレントニューラルネットワークの一つである LSTM(Long short-term memory)に投入して推定する手法を提案する。

2. 関連研究

本章にて、スマートフォンのセンサから得られた加速度データを解析する研究で、本研究と関連の強いものを示す。

最初にスマートフォンやウェアラブル端末に搭載されているセンサから得られたデータを機械学習などにより解

析する研究を示す。Kobayashi らは、スマートフォンの加速度センサや GPS から得られたデータを解析してユーザの動作を推定する手法を提案している[1]。Song らは、ウェアラブルセンサモジュールの加速度センサから得られた加速度データを解析してユーザの行動を認識する手法を提案している[2]。Bouten らは、行動を推定するための携帯可能な加速度センサとデータ処理ユニットを提案している[4]。Eren らは、スマートフォンの加速度センサ、ジャイロスコープ、磁力計を用いて運転者の振る舞いを予測し、その運転者の通勤の安全性を見積もる手法を提案している[5]。これら研究により、ユーザの動作などは高い精度での推定が実現されている。しかし、スマートフォンを保持しているユーザの推定は行われていない。

次にセンサデータの解析からユーザー個人を推定する研究を示す。Lane らは携帯端末のセンサについて包括的な調査の結果を報告している[6]。そして、若者と老人の歩行に携帯端末から得られたセンサデータに大きな差があることを示している。Shi らは、スマートフォンのセンサーからキャプチャしたデータを解析しユーザー識別を実行するユーザ認証フレームワーク SenGuard を提案している[7]。そして、音声、位置情報、マルチタッチ情報、移動情報の 4 つの観察された情報から認証を行うシステムを実装し、これらが認証に適していることを示している。Shi らの研究では個人の特定に取り組んでいるが、単純な統計値を用いるに留まっており LSTM の様な解析手法は使用されておらず、評価も 2 クラス分類の様な単純なものにとどまっている。

佐藤らは歩きスマホの状態のスマートフォンの加速度センサから得た加速度情報を機械学習を用いて解析することよりユーザーを推定する手法を提案している[3][8]。与え

1 工学院大学
Kogakuin, University
2 長崎大学
Nagasaki University

3 お茶の水女子大学
Ochanomizu University

られた加速度が、既知の対象ユーザー2人のうちのどちらのものであるのかという推定を行っている。機械学習にはDNNを用いている。また加速度データを2秒ごとに区切りそれを昇順にソートしたものを学習データとして用いている。このソートしたデータをX軸、Y軸、Z軸ごとに使用する手法と3軸の絶対値を使用する手法の合計4つの手法による推定を行っている。性能評価ではX軸のみを用いた場合が最も正解率が高く87%となっている。この研究と本研究は目的が一致しているが相違点がある。本研究ではDNNではなくLSTMを使用している。そのため加速度データを時系列データとして学習することができる。そして、本研究では加速度データを時系列データとして学習している。これにより、個人の時間変化による特徴もとらえられと考えられ佐藤らの研究[3]より正解率の向上が期待できる。

3. 提案手法

本章で加速度センサーから得た加速度を機械学習を用いて学習し個人を推定する手法について述べる。

3.1 提案手法の概要

本節にて加速度データからユーザーを推定する2つの手法の概要を説明する。一つは出力に「不明」を含まない一般的な手法であり比較のために「不明なし推定手法」と呼ぶ。もう一つは出力に「不明」を含む特殊な手法であり「不明あり推定手法」と呼ぶ。

最初に、不明なし推定手法について述べる。本手法は三段階に分かれている。第一段階では事前学習用に各推定対象者の歩きスマホ時の加速度を測定する。第二段階では測定した各被験者の事前学習用データを用いてLSTMにより学習を行いモデルを構築する。第三段階では入力データ(推定用データ)を前段階で構築したモデルで解析し、入力データのユーザーを推定する。学習と評価には3.5節に示すネットワークを使用する。ネットワークは必ず推定結果を出力し、出力結果は正解か不正解のいずれかにより評価される。

次に、不明あり推定手法について説明する。本手法も三段階に分かれていて、第一段階と第二段階は不明なし推定手法と同じである。第三段階では入力データを第二段階で構築したモデルで解析し入力データのユーザーの推定を試みるが、結果としては推定結果のユーザーまたは不明を出力する。具体的には、各ユーザーである確率を示すネットワーク最終層のソフトマックス関数の出力が、あるユーザーにて0.9を超えている場合はそのユーザーを推定結果とし出力し、超えているユーザーが存在しない場合は「不明」を出力する。

前者は汎用目的でLSTMを用いる推定手法の性能を評価するために使用し、後者は認証などの誤推定が大きな問題であるが判定不能(別の判定方法を促すなど)が大きな問題とならない事例における性能を評価するために用いる。

3.2 推定対象

本推定では、推定システムがあるユーザーの歩行時の加速度時系列データを与えられ、それが既知の n 人の中のどのユーザーの加速度であるかを推定する。既知の n 人の学習用の加速度データは与えられており、推定の前にモデルを構築することが可能であるとする。

3.3 歩行時の加速度データの取得

各推定対象者の歩行時の加速度データを次の方法で取得した。各推定対象者にスマートフォンを持った状態で「普段通りに歩きスマホをしてください」と伝えて、安全な場所を歩いてもらった。その際にはスタッフが同行し、被験者の安全を確保した。全被験者が歩いた場所はすべて同じ道である。

本稿では加速度測定のためのAndroidアプリケーションを実装し、それをインストールしたスマートフォンを推定対象である被験者に使用させて加速度を計測した。このアプリケーションはGoogle APIを用いて約20msごとに加速度を取得する。同APIにて取得できる加速度はX軸、Y軸、Z軸の三軸方向のものである。計測される加速度方向は図1のようになっている。各軸の正の向き(X軸であれば右が正か左が正か)は端末の実装に依存しているが、本提案手法は軸の向きに対して対称であるため性能は正の向きに依存しない。




図1 スマートフォンの加速度方向
Figure 1 Smartphone acceleration direction

3.4 入力データ

提案手法では、固定長の加速度時系列データを推定システムに与え学習と推定を行う。LSTMを用いて時系列データを処理しており、可変長のデータへの対応は容易であるが、各推定の条件を均一にし比較などをしやすくするため本稿では各推定の入力時系列長を固定として、各ユーザーの全時系列データ長も固定とした。そのため図2に示すように被験者から得た加速度データの余分な部分を削除した。加速度データの最初の2秒分を削除するのはAndroidアプリケーションの操作時の加速度データを除くためである。余分な部分を削除した「機械学習に使用する加速度データ」

が被験者一人分の加速度データである。図2に用いているセットという単位は一度に測定したX軸、Y軸、Z軸を合わせたものを1セットとしている。

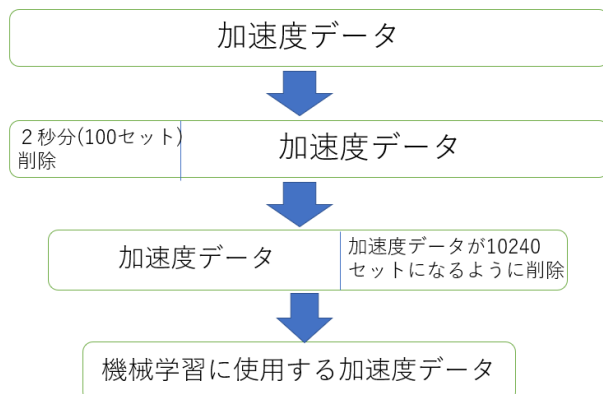


図2 入力データの作成方法

Figure 2 Input data division method

3.5 使用するネットワーク

本手法では、LSTMを用いて加速度より個人推定を行う。入力層の次元数は使用する加速度の軸方向の数によって異なる。例えばX軸のみを使用する場合は入力層次元数は1、X軸、Y軸、Z軸の三つを使用する場合は入力層次元数は3となる。出力層は分類クラス数によって次元数が異なる。 n クラス分類なら出力層次元数は n となる。

ネットワークの出力の各次元の値は、入力データが各クラスの推定対象ユーザである確率である。

表1 ネットワークのハイパーパラメータ

Table 1 Network hyperparameters

ネットワークのハイパーパラメータ	
活性化関数	ソフトマックス関数
誤差関数	クロスエントロピー
最適化関数	Adagrad
中間層次元数	100
中間層数	1

3.6 推定に使用する加速度の軸方向

佐藤らの研究[3]にて、推定に使用する加速度の軸方向により推定精度(正解率)が大きく異なることが示されている。最低正解率と最高正解率の差は40%であった。本稿でも事前に各軸および各軸の組み合わせを使用した際の正解率を調査し、それにより使用する加速度軸(あるいは軸の組み合わせ)を決定した。




図3 各軸方向の正解率

Figure 3 Correct rate in each axis

5クラス分類の結果を図3に示す。推定を行った際のハイパーパラメータは表1の通りである。また中間層にはLSTMを用いており、学習と評価には25分割交差検証を用いた。図3の例にて3軸すべてを使用したモデルが最も正解率が高くなっている。よって本稿における提案手法では3軸すべてを使用することとする。

4. 性能評価

本章にて性能評価を行う。5人の被験者(推定対象者)に同じ道を歩きスマホをしながら歩いてもらい、その際の加速度を提案手法のアプリケーションで測定した。

計測したデータを全ユーザで同一の長さの時系列データとするために図2の処理を行った。本稿では、各ユーザの加速度(三次元ベクトル)の個数を10240セットとした。計測の最初付近は歩行中でない可能性があるため全ユーザ最初の2秒間のデータを削除し、その後10240セットとなるように計測データを最後の方から除外していった。実験端末では1秒間に50個の加速度(ベクトル)を取得できるため、10240セットの加速度は204.8秒の歩行の加速度データである。5人の被験者は、18~24歳の男性大学生/大学院生4名と40代男性1名である。本稿では各被験者をA~Eと呼ぶ。

LSTMのニューラルネットワークの中間層次元数は100、隠れ層数は1とした。ハイパーパラメータは表1の通りである。計測を行ったスマートフォンはNexus5xであり、OSとしてAndroid 7.1.1を搭載している。本端末の各軸の正の向きは図1の通りである。LSTM実装はPytorch1.6を用いた。ネットワークのハイパーパラメータは表1の通りである。推定のための学習と評価は交差検証を用いた。2クラス分類では10分割交差検証を行い、3クラスでは15分割、4クラスでは20分割、5クラスでは25分割の交差検証を行った。

4.1 不明なし推定手法

まず、不明なし推定手法の評価を行う。2~5クラス推定を行い、平均正解率を求めた。被験者が5名いるため、2~4

クラス分類では被験者組み合わせごとに学習と評価を行った。例えば2クラス分類の場合は、AとBの組、AとCの組、AとDの組のように $sC_2=10$ 通りの組にて評価を行った。推定システムには40秒(加速度2000セット)の加速度を与えユーザ推定を行った。

図4に2~5クラス分類の平均正解率を示す。図からLSTMを用いる本手法は2~5クラス分類のすべてで95%以上の平均正解率を得ることに成功しているのがわかる。佐藤らの手法[3]では2クラス分類における正解率の最大値が87%であり、LSTM2Mを用いる本手法が佐藤らの手法より2クラス分類にて8%高い正解率を実現していることが分かる。




図4 平均正解率で評価した2~5クラス分類結果
Figure 4 2-5 class classification results evaluated by average correct answer rate




図5 入力データを40秒とした場合の結果
Figure 5 Result when input data is 40 seconds




図6 入力データを20秒とした場合の結果
Figure 6 Result when input data is 20 seconds




図7 入力データを10秒とした場合の結果
Figure 7 Result when input data is 10 seconds

4.2 入力加速度量と正解率

次に、不明なし推定手法を用いて、推定システムに入力する加速度の量(三次元ベクトルの数)と正解率の関係について調査する。

図5~7に5クラス分類にて、推定システムのLSTMネットワークに入力する歩きスマホ時間(データ量)を10秒、20秒、40秒と変更して評価した結果を示す。図の横軸のA~Eは正解ユーザを表しており、AVERAGEはA~Eの正解率の平均値を表している。

図より、入力するデータ量が減るごとに平均正解率が低下していることがわかる。また、正解率の低下は一部のユーザ(BとE)にて顕著に現れていることがわかる。

4.3 不明あり推定手法

次に、不明あり推定手法の評価を行う。入力加速度データの時間が10秒から40秒の同手法での5クラス分類の推定結果を図8~10に示す。この手法は推定結果ユーザあるいは不明を出力する。推定結果ユーザを出力した場合、評価結果は正解(correct)あるいは不正解(incorrect)となる。不明を出力した場合は、評価結果は常に不明(unknown)となる。




図 8 入力時間 40 秒の不明あり推定手法の結果

Figure 8 Results of estimation method with unknown input time of 40 seconds




図 9 入力時間 20 秒の不明あり推定手法の結果

Figure 9 Results of estimation method with unknown input time of 20 seconds




図 10 入力時間 10 秒の不明あり推定手法の結果

Figure 10 Results of estimation method with unknown input time of 10 seconds

図 8 では、A において 20%の不明が生じているが、AVERAGE の不正解率は 0%となっている。図 5 における不明なし推定の AVERAGE の正解率が 96%であり、不正解率は 4%である。よって、不明を導入したことにより不正解率を下げる事ができたことがわかる。同様にして図 6 と図 9 の 20 秒における AVERAGE を比較すると、不明の導入により不正解率が 9%低下しており、図 7 と図 10 の AVERAGE を比較すると不正解率が 11%低下していることがわかる。これらのことから、不明を導入することにより不正解率の低減を達成できていることがわかる。

5. 考察

まず不明なし手法の精度向上手法について考察する。図 5-7 を見ると一度に入力するデータ量(これはデータの時間と比例する)が増えるごとに平均正解率が高くなるのがわかる。これは LSTM には時系列データを入力するため、入力データの量やデータがカバーする時間が長いほうが個人の特徴をとらえやすいからだと考えられる。入力するデータの歩行時間を変えずにデータの量を増やす方法として、加速度の測定間隔を短くする方法がある。本稿で使用したアプリケーションでは 20ms ごとに加速度を集計しているが、2ms ごとに測定することもできる。2ms ごとに測定することにより同じ秒数でも計測加速度データの数を増やすことができる。正解率向上の原因としては、データ数の増加、データがカバーする時間の拡大、その両方などが考えられるが、データ数の増加が原因となっている場合は計測間隔の短縮による正解率の向上も考えられる。

また、最適化関数のチューニングによる改善も考えられる。本稿では最適化関数として Adagrad を使用した例を紹介したが、Adam を用いると 5 クラス分類の正解率が 15%以上低下することが確認されている。正解率は最適化関数の選択に影響され、別の関数の選択することで正解率が向上する可能性があると考えられる。

次に不明を導入した手法について考察する。不明あり手法は、不明なし手法より不正解率を低下させることに成功している。特に入力データ長が 40 秒(2000 セット)の例においては不正解率 0%を実現しながら高い正解率も実現しており、理想に近い結果と言える。しかし、データ長が 10 秒や 20 秒では、確率は低い不正解が存在している。不正解率を低減させる簡易な手段として、推定結果を出力するか不明を出力するかを閾値を向上させる方法が考えられる。本稿では閾値を 0.9 とし、ソフトマックス関数の出力値の最大値が 0.9 より小さいときに不明を出力しているが、この閾値を 0.95 などによって不明を出力する確率が上がり不正解率が下がると考えられる。ただし、これは正解率の低下も招くため応用に対して調整する必要があると言える。図 10 を見ると B, C, E において高い不明の率を示している。この三名は LSTM による分類の側面にお

いて互いに歩きスマホ時加速度の特徴が似ていると予想される。図 11~13 に入力データが 10 秒の場合の LSTM ネットワークの出力値を示す。図 11~13 の横軸は何個目のテストデータかを表し、縦軸は LSTM ネットワークが出力した各対象者である確率を表している。図に掲載しているテストデータは、ネットワークの出力が不明であったものか、不正解となったものである。B, C, E 間において推定の誤り多く生じていることを確認できる。これら被験者は年代が近く、性別が同じであることが類似している原因である可能性も考えられる。その場合は、これを活用してユーザの年代や性別を推定する応用なども考えられる。

次に、ユーザがスマートフォンを保持する方法について考察を行う。本稿では、加速度の変動が比較的少ないと予想される事例として歩きスマホの状態に着目して考察を行い、5 クラス分類にて高い精度で推定できることを示した。よって、歩きスマホの状態（すなわちユーザがスクリーンの方向をむいている状態）でなくても、手に持ち安定している状況であればある程度の精度で推定ができる可能性が考えられる。




図 11 テストデータが B 時のモデルの出力
Figure 11 Model output when test data is B




図 12 テストデータが C 時のモデルの出力
Figure 12 Model output when test data is C




図 13 テストデータが E 時のモデルの出力
Figure 13 Model output when test data is E

6. まとめ

本稿では加速度データを LSTM を用いて解析することでスマートフォンを保有している個人を推定する手法を提案した。そして、LSTM を用いることにより佐藤らの手法[3]よりも高い精度で推定できることを確認した。また、不明を導入した手法では不明なし推定手法よりも不正解率を低くできることを確認した。

今後の課題としては、5 クラス分類より多いクラスの分類の性能の評価、少ない入力データで高い精度を実現する手法についての考察、歩きスマホ以外の使用状況における評価などを考えている。

謝辞

本研究は JSPS 科研費 17K00109, 18K11277 の助成を受けたものである。

本研究は、JST、CREST JPMJCR1503 の支援を受けたものである。

参考文献

- [1] Arei Kobayashi, Shigeki Muramatsu, Daisuke Kamisaka, Takafumi Watanabe, Atsunori Minamikawa, Takeshi Iwamoto, and Hiroyuki Yokoyama. Shaka: User movement estimation considering reliability, power saving, and latency using mobile phone. *IEICE TRANSACTIONS on Information and Systems*, Vol. E94-D, No. 6, pp. 1153--1163, 2011.
- [2] S. k. Song, J. Jang and S. Park, "A Phone for Human Activity Recognition Using Triaxial Acceleration Sensor," 2008 Digest of Technical Papers - International Conference on Consumer Electronics, Las Vegas, NV, 2008, pp. 1-2. doi: 10.1109/ICCE.2008.4587903
- [3] 佐藤 悠祐, 神山 剛, 福田 晃, 小口 正人, 山口 実靖, “加速度センサによるスマートフォンユーザの推定に関する考察”, *IPSI 研究報告コンシューマ・デバイス&システム (CDS)*, 2019-CDS-26 巻, 2 号, pp. 1 - 6, 2019
- [4] C. V. C. Bouten, K. T. M. Koekkoek, M. Verduin, R. Kodde and J. D. Janssen, "A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity," in *IEEE Transactions on Biomedical Engineering*, vol. 44, no. 3, pp. 136-147, March 1997. doi: 10.1109/10.554760
- [5] H. Eren, S. Makinist, E. Akin and A. Yilmaz. 2012. Estimating

- driving behavior by a smartphone. 2012 IEEE Intelligent Vehicles Symposium, Alcalá de Henares. pp. 234-239. doi: 10.1109/IVS.2012.6232298
- [6] N. D. Lane, E. Miluzzo, H. Lu, D. Peebles, T. Choudhury and A. T. Campbell. 2010. A survey of mobile phone sensing. in IEEE Communications Magazine, vol. 48, no. 9, pp. 140-150, Sept. doi: 10.1109/MCOM.2010.5560598
- [7] W. Shi, J. Yang, Yifei Jiang, Feng Yang and Yingen Xiong. 2011. SenGuard: Passive user identification on smartphones using multiple sensors, 2011 IEEE 7th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob). Wuhan. pp. 141-148. doi: 10.1109/WiMOB.2011.6085412
- [8] Yusuke Sato, Shun Kurihara, Shoki Fukuda, Masato Oguchi, and Saneyasu Yamaguchi. 2017. Height Estimation based on Sensor Data on Smartphone. In Proceedings of the 15th International Conference on Advances in Mobile Computing & Multimedia (MoMM2017). Association for Computing Machinery, New York, NY, USA, 102–106.
DOI:<https://doi.org/10.1145/3151848.3151877>