

# スマートフォンに搭載されている加速度センサー情報を用いた 2 クラスの分類による身長推定

佐藤 悠祐<sup>†1</sup> 神山 剛<sup>†2</sup> 福田 晃<sup>†2</sup> 小口 正人<sup>†3</sup> 山口 実靖<sup>†1</sup>

**概要:** 近年、センサーと機械学習を用いた様々な研究が行われている。例えば、スマートフォンの加速度センサーから得られた情報を解析しユーザーの動きを予測する取り組みなどが行われており、高い精度を達成している。本研究では、これらのユーザー情報を予測する研究におけるより発展した取り組みとして、加速度センサーの値からユーザーの身長を推定することに取り組む。本稿では、本研究の初期段階として被験者の身長を 2 つのクラスに分類し、このクラスの推定を行う。また、ユーザーがスマートフォンを手に持ちながら歩いている状況に着目し、この状態において得られたセンサー値からの推定を行う。まず既存の手法として、加速度センサーの値から統計値などを抽出し SVM を用いて解析する既存の手法を紹介する。そしてその手法を歩数の自動抽出と線形回帰を用いて改善し、加速度センサーの値から被験者の身長を推定する手法を提案する。最後に、その手法の評価を行い、有効性を示す。

**キーワード:** 身長推定, スマートフォン, 三軸方向加速度センサー, 機械学習, 線形回帰

## 1. はじめに

近年、機械学習の発展やスマートフォンの普及によって、様々なセンサー情報を用いた推定が可能になった。その一例としてスマートフォンのユーザーの行動の推定が挙げられる[1][2][3][4][5]。センサー情報を用いたユーザー情報の推定は、ユーザーの ID の情報を用いないことによるユーザーの匿名性の確保等、様々な目的に使用されている。本研究では、機械学習を用いた推定のさらに発展した研究として、スマートフォンから取得したセンサー情報を用いてユーザーの身長を推定することを目的としている。この目的の研究の初期段階として本稿では、3 軸方向の加速度センサーをから取得した情報を用いて歩行しているユーザーの身長を 2 クラス(高い, 低い)に分類し、このクラスの分類に取り組み、線形回帰によってユーザーの身長のクラス(高いか, 低い)推定する手法を提案する。次に、提案手法を 29 人の歩行中のユーザーの三軸方向の加速度センサーの情報に用いて性能を調査する。

## 2. 三軸方向加速度センサー

### 2.1 スマートフォン上での加速度センサーの 3 軸方向

多くのスマートフォンには三軸方向加速度センサーが搭載されている。このセンサーからは、3 軸方向の加速度の値を取得することが可能である。図 1 はスマートフォン搭載の三軸方向加速度センサーのそれぞれの軸を示したものである。画面の横軸方向が x 軸、画面の縦軸方向が y 軸、画面に対して垂直な方向が z 軸の値である。

### 2.2 Android における三軸方向加速度センサー

Android OS は、スマートフォンオペレーティングシステムとして広く普及しており[6][7][8][9][10][11]、本稿では同 OS および同 OS を搭載したスマートフォン端末を用い

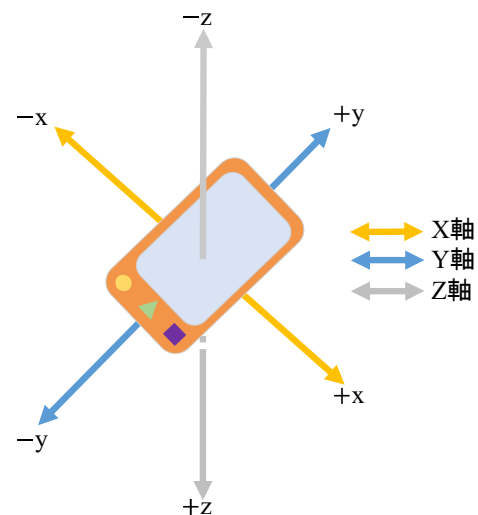


図 1 スマートフォンにおける三軸方向

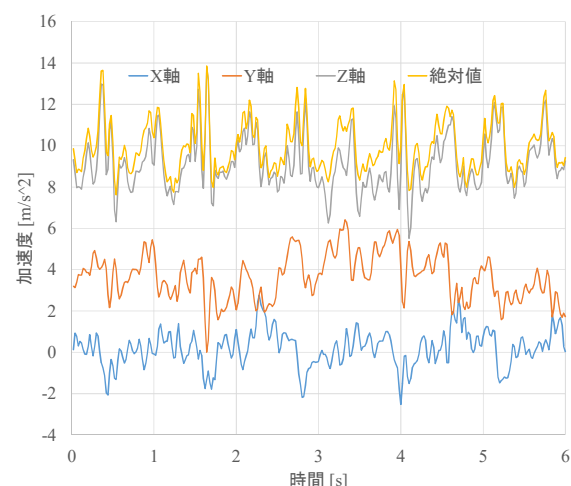


図 2 加速度センサーから取得した値

<sup>†1</sup> 工学院大学  
Kogakuin University  
<sup>†2</sup> 九州大学  
Kyushu University

<sup>†3</sup> お茶の水女子大  
Ochanomizu University




図3 加速度センサーの値を用いた1歩の検出

て評価を行う。Android 端末では、Android フレームワーク上のクラスの一つである `SensorManager` を用いて 3 軸方向加速度センサーから加速度の値を取得することが可能である。図 2 は本稿の実験で用いた Android 端末である Nexus 5 から取得した加速度の値の例を示したものである。

### 3. 関連研究

Lane らは携帯端末のセンシング技術について総合的な調査を実施している[1][9]。Lane らは取得したセンサーデータを解析し、若者と老人の歩行により得られるデータの間には大きな差があると主張している。ただし、当該論文ではユーザーの身長を推定する手法については考察されていない。

多くの論文[2][4][5][13][14]で、スマートフォンに搭載されているセンサーを利用してユーザーの動作を検知する取り組みが実施されている。Eren らは、スマートフォンを用いて運転者の振る舞いを理解する手法を提案している[13][2]。Kobayashi らは、スマートフォンに搭載されている加速度センサーや GPS を用いてユーザーの動作を確認する手法を提案している[2]。この手法は動作のみならず消費電力の軽減にも焦点を当てている。Song らは、3 軸方向加速度センサーを含むウェアラブルなセンサーモジュールを用いて特に高齢者の行動を認識する手法を提案している[3]。Khan らは加速度センサーに基づき人間の行動を認識する手法を発表している[4][14]。Bouten らは、日々の肉体的な行動を評価するための携帯可能な 3 軸方向の加速度センサーとデータ処理ユニットを開発している[5]。Shi らは、持続的で暗黙のユーザー認証サービスをモバイルシステムで提供することが可能な携帯ユーザー認識管理ソリューションを提案している[14]。Shi らは、暗黙の携帯ユーザー認識のためのデータソースとしていくつかの方式が最適であることを証明している。本稿の提案手法はこれらの既存手法に基づいているが、これらの既存の研究ではユーザーの身長を推定する手法については言及されていない。

本研究の先行研究では、スマートフォン搭載の 3 軸方向の加速度センサーから取得した加速度のデータを利用した

ユーザーの身長推定を行う 3 種類の手法が提案されている[15]。1 つ目の手法では、16 種類の統計学上の値を特徴量として SVM (Support Vector Machine) に入力して学習及び分類を行っている。2 つ目の手法では、ユーザーの歩数を特徴量として SVM に入力して学習及び分類を行っている。3 つ目の手法では、16 種類の統計学値と歩数の両方を特徴量として SVM に入力して学習及び分類を行っている。先行研究では実際に複数のユーザーから取得したデータでこれらの手法の性能を調査した。具体的には、すべてのユーザーがスマートフォンを手にしている状態で歩行して加速度を取得し、取得したデータをこれらの 3 つの手法で解析(学習と分類)した。そして、2 つ目の手法(ユーザーの歩数を特徴量として SVM で学習及び分類するもの)が最も高い正解率で分類できることが確認された。ただし、その正解率は 68%にとどまり、これらの手法には改善の余地があると考えられる。

### 4. 提案手法

本章にて、加速度センサーから取得した加速度の値から身長を推定する手法を提案する。

#### 4.1 推定対象

本節にて、本手法の推定対象について説明する。本稿では被験者全体を身長の高低で 2 つのグループに分類し、各被験者がどちらのグループに分類されるかを推定した。高身長グループは身長が「被験者全体の身長の中間値」以上の被験者のグループである。低身長グループは身長が中間値未満のグループである。本稿では、一般に「歩きスマホ」と呼ばれているスマートフォンの画面を見ながら歩行している状態にて加速度センサーから得られた加速度に着目し、推定を行う。これは他の状態(スマートフォンをズボンのポケットに入れた状態等)よりも安定した加速度の値が取得できるからであり、本考察の初期段階として歩きスマホでの 2 グループ分類による身長推定というより容易な推定を対象としている。

#### 4.2 手法の概要

図 4 は本稿の提案手法を用いた推定方法の概要である。本稿の提案手法は 4 つの段階で構成されている。最初の段階では、各被験者のセンサー情報を取得する。本稿では、Google API を用いて加速度センサーの情報を取得している。次の段階では、取得した加速度センサーの値から歩数を抽出し、これを特徴量とする。さらに次の段階では、上記のデータを用いて機械学習による学習を行い、モデルを作成する。入力データは各被験者の歩数と身長であり、身長が正解である。機械学習としては線形回帰を用いる。最後の段階では、身長が不明である分類対象の被験者の加速度データを前段階で作成したモデルにより身長の推定を行い、推定身長により身長の高低の分類を行う。

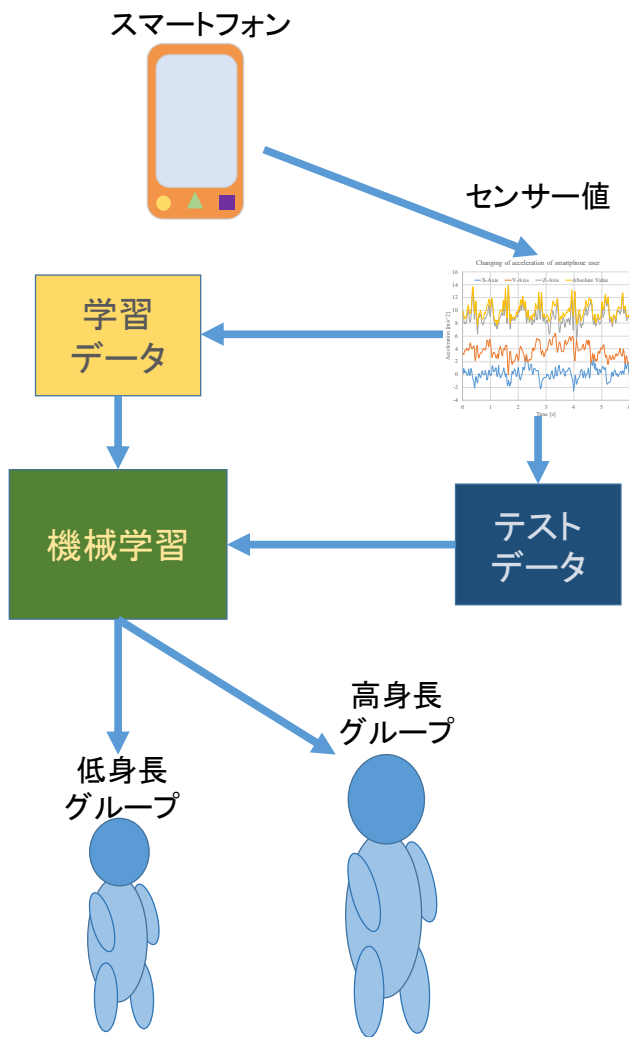


図4 データの取得から分類までの概要



図5 計測中の被験者の状態(歩きスマホ)

#### 4.3 歩数の推定

この節では加速度の値から歩数を推定する方法について説明する。

初めに、各時刻の  $-n$  ms から  $+n$  ms の長さ  $2n$  ms の区間の加速度値の移動平均を計算し、取得した加速度のノイズを軽減する。次に、下記の計算式で定義される閾値を計算する。

$$Th = \frac{A_{max} + A_{min}}{2}$$

$A_{max}$  は各時刻から過去  $m$  ms 間の移動平均の最大値、 $A_{min}$  は最小値である。移動平均は現在の時刻を中心とする区間を対象としており、現在を表す値である。閾値は  $m/2$  ms 過去を中心とする区間 ( $m$  ms 過去から現在) を対象としており、過去を表している。

移動平均が閾値の値を超える形で両者が交わった時(移動平均 < 閾値 から 閾値 < 移動平均 に変化したときに)、1 歩が発生したとして測定する。そして、求めた歩数の合計を、この歩数を歩く時に要した時間で割り、1 秒辺りの歩数を、次の節の線形回帰における特徴量として用いる。

また、加速度のグラフから人手で歩数を測定する事も可能であり、本稿の上記アルゴリズムを用いて推定した歩数を用いた評価と、手動で推定した歩数を用いた評価の両方を行う。

#### 5. 性能調査

29 人の被験者からデータを収集した。全ての被験者に、加速度の値を取得及び記録するためのアプリケーションがインストールされた一台のスマートフォンを持たせ、計測を実施した。被験者はスマートフォンを手に持って画面を見ている状態で 20~30 メートルの平坦で直線的な道を歩行した。図 5 は計測中の被験者の状態を示した図である。全ての被験者が一般に歩きスマホと呼ばれている状態で歩行した。被験者の安全を確保するため、歩行は安全な屋内にて補助者が見守りながら行った。被験者は 3 人の女性と 26 人の男性で構成され、全員 18 歳以上 22 歳以下の大学生である。

取得した被験者を、被験者の身長の間接値を基準に身長が高いグループと低いグループの 2 つのクラスに分類した。身長は本人の申告値を用い、中間値は 168 cm であった。被験者数が 29 であったため、中間値の被験者のデータを除外し、残り 28 人の被験者のデータを上記の 2 グループに分類した。従って 2 グループのそれぞれの人数は 14 人である。表 1 は高身長グループと低身長グループそれぞれに含まれる被験者の身長及び人数を示したものである。

計測には Nexus 5x を用いた。インストールされているセンサー値を取得するためのアプリケーションは、20 ms 毎にセンサー値を取得する。計測結果の最初と最後には、スマートフォンを操作しており歩行中でない時間帯における計測値が含まれているため、取得したデータの最初と最後のそれぞれ 2 秒分のデータは除外した。歩数の推定のアルゴリズムのパラメータである  $n$  と  $m$  はそれぞれ 60 ms と 200 ms とした。

4 章で述べた様に、歩数の推定は 4 章 3 節で述べた方法と、手動による推定の両方を用いた。線形回帰には tensor flow 1.4.0 を用いた。表 3 は本稿での実験環境を示したものである。学習と分類には 14-分割交差検証(14-fold cross validation)を用いた。

表 1. 低身長グループ

低身長グループ	
身長 [cm]	人数 [人]
149	1
152	1
162	2
164	1
165	2
166	1
167	5
168	1

表 2. 高身長グループ

高身長グループ	
身長 [cm]	人数 [人]
170	1
171	1
173	2
174	1
175	1
178	1
180	1
181	1
182	2
183	1
185	1

表 3. 実験環境

スマートフォン	モデル	Nexus 5X
	Android OS	7.1.1 (Nougat)
線形回帰	使用ライブラリ	Tensor Flow
	バージョン	1.4.0

### 5.1 実験結果

図 6 に, 既存手法[9]と本稿の提案手法の正解率を示す. 提案手法の歩数自動推定は 4 章 3 節で述べた推定アルゴリズム




図 6 既存手法と提案手法の正解率

ムによる歩数の推定によるものであつたことより, 提案手法が既存手法を上回る正解率で分類をできていることがわかる. 提案手法同士の正解率を比較すると, 歩数手動検出を用いたものが自動検出を用いたものを 25% 上回る結果となっている.

既存手法の正解率を比較すると, 歩数を用いた手法が他の手法に比べて高い正解率で分類したことが分かる. これらの結果は歩数を利用することがユーザーの身長を推定する上で効果的であることを示している. また, 歩数を用いた手法同士を比較すると, SVM を利用するより線形回帰を用いることがより効果的であることがわかる. 自動検出による歩数の測定と手動検出による歩数の測定を比べると, 手動検出の方がより高い精度で分類しており, 本研究における自動検出には性能を向上させるが余地あることがわかる.

図 7 は被験者を 3 つのグループで分割し, それぞれのグループのデータを用いた分類をした結果を示している. 1 つのグループは *Far from median* グループであり, 身長が中間値から遠い被験者のみで構成されている. 具体的には, 今回の被験者の中で最も身長が高い 4 名と最も低い 4 名で構成されたグループである. *Near to median* グループは身長が中間値に最も近い被験者 8 名(高身長グループと低身長グループそれぞれから 4 名)で構成されるグループである. *Middle* グループは, 身長と中間値の差が上記の 2 グループの中間に位置する 8 名(各グループ 4 名)で構成されるグループである. 分類対象の身長の差が大きくなるにつれて, 分類の難易度は低くなると考えられる. 図の結果も, *Far from median* グループは最も高い正解率で分類し, *Near to median* グループは最も低い正解率で分類したことを示している. よって, 提案手法は適切な推定をしていると期待できる. 一方で, 既存手法はこの特徴を示さしていない. よって, 提案手法は既存手法に比べてより適切な推定をしていると考えられる.



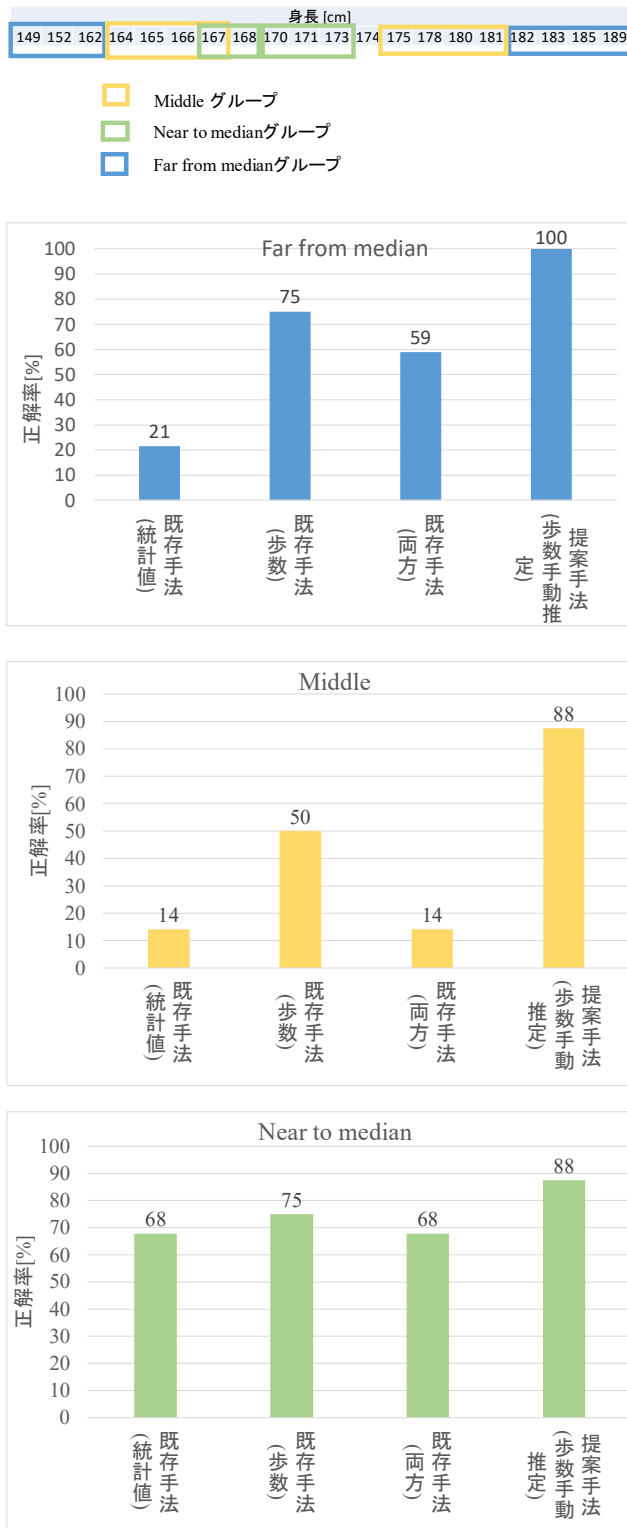


図7 グループ別の既存手法と提案手法の正解率

## 6. 考察

はじめに、身長推定の意義について考察する。スマートフォンに内蔵されているセンサーの性能が向上しており、近い将来にスマートフォンはユーザーの健康を管理する上で重要なデバイスになる可能性が考えられる。健康を管理

する上では、ユーザーの様々な身体情報が必要となるが、身長はユーザーの健康上で重要な情報の1つになると考えられる。

ユーザーの健康状態を知る情報の中ではユーザーの体重も重要であると考えられる。体重が重いユーザーと軽いユーザーの間には取得したセンサー情報に差が生じる可能性がある。これに加えて、健康状態が良いユーザーと悪いユーザーの間でも同様に差が生じる可能性がある。本稿における身長推定への取り組みと考察は、上記の挑戦へ貢献できると期待できる。

続いて、本研究の提案手法について考察する。前章で述べたように、歩数の自動検出による身長推定の精度は、歩数の手動検出による推定の精度よりも低い。従って、歩数の検出の精度の向上は重要な課題の1つであると考えられる。図3より、歩数の自動検出アルゴリズムのパラメータである  $n$  や  $m$  が重要であること分かる。これらのパラメータ  $n$  と  $m$  を調整し、2種類のグラフの周期のずれが半周期になるように調整することが効果的であると考えられる。位相のずれが半周期となれば、交わる点における2つのグラフの変化が大きく異なる様になり、ノイズなどの影響を受けづらくなると予想される。

## 7. おわりに

本稿ではスマートフォンに搭載されている加速度センサーから取得した情報を用いてスマートフォンのユーザーの身長を推定する手法を提案した。その手法はユーザーの歩数を特徴量として線形回帰に用いて学習と分類を行うものである。そして、29人の被験者のデータを用いてこの手法の性能を評価した。本稿の性能調査において、提案手法は既存の手法よりも25%高い精度でユーザーの身長を推定することができ、提案手法の有効性が示された。

今後は、歩数の推定の精度の向上に関する考察、さらに多くの被験者のデータによる評価、身長以外の情報の推定に関する考察を行っていく予定である。

### 謝辞

本研究は JSPS 科研費 15H02696, 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] SVMlight Support Vector Machine: <http://svmlight.joachims.org/>
- [2] 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.
- [3] 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
- [4] A. M. Khan, Y. K. Lee, S. Y. Lee and T. S. Kim, "A Triaxial Accelerometer-Based Physical-Activity Recognition via Augmented-Signal Features and a Hierarchical Recognizer," in *IEEE Transactions on Information Technology in Biomedicine*, vol. 14, no. 5, pp. 1166-1172, Sept. 2010. doi: 10.1109/TITB.2010.2051955
- [5] 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
- [6] Global mobile OS market share in sales to end users from 1st quarter 2009 to 1st quarter 2016: available from <https://www.statista.com/statistics/266136/global-market-share-held-by-smartphone-operating-systems/>
- [7] Smartphone OS Market Share, 2016 Q3: available from <http://www.idc.com/promo/smartphone-market-share/os>
- [8] Gartner Says Five of Top 10 Worldwide Mobile Phone Vendors Increased Sales in Second Quarter of 2016: <http://www.gartner.com/newsroom/id/3415117>
- [9] K. Nagata, S. Yamaguchi and H. Ogawa, "A Power Saving Method with Consideration of Performance in Android Terminals," *2012 9th International Conference on Ubiquitous Intelligence and Computing and 9th International Conference on Autonomic and Trusted Computing*, Fukuoka, 2012, pp. 578-585. doi: 10.1109/UIC-ATC.2012.133
- [10] K. Nagata and S. Yamaguchi, "An Android application launch analyzing system," *2012 8th International Conference on Computing Technology and Information Management (NCM and ICNIT)*, Seoul, 2012, pp. 76-81.
- [11] Yuta Nakamura, Kyosuke Nagata, Shun Nomura, and Saneyasu Yamaguchi. 2014. I/O scheduling in Android devices with flash storage. In *Proceedings of the 8th International Conference on Ubiquitous Information Management and Communication (ICUIMC '14)*. ACM, New York, NY, USA, Article 83 , 7 pages. DOI: <https://doi.org/10.1145/2557977.2558025>
- [12] 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
- [13] 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
- [14] 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
- [15] 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)*, Eric Pardede, Pari Delir Haghighi, Ivan Luiz Salvadori, Matthias Steinbauer, Ismail Khalil, and Gabriele Anderst-Kotsis (Eds.). ACM, New York, NY, USA, 102-106. DOI: <https://doi.org/10.1145/3151848.3151877>