

加速度及びジャイロスコープセンサデータを用いた スマートフォンアプリケーションの推定

柄澤 匠^{1,a)} 浜中 智己^{2,b)} 佐々木 航^{2,c)} 大越 匡^{1,d)} 中澤 仁^{1,e)}

概要: スマートフォンアプリケーションのスクリーンタイムデータは、ユーザが使用したアプリケーションの使用時間やスマートフォン画面の起動時間などのユーザ情報を客観的かつ正確に反映している。一方でスクリーンタイムデータの取得はユーザプライバシーの観点から制限される場合が多く、データ活用の機会は著しく少ない。本研究では上記の課題を解決するため、スクリーンタイムデータの代わりにスマートフォンに標準的に搭載される加速度及びジャイロスコープセンサデータに着目し、使用されたアプリケーションの推定を行った。実験では男女計 10 名を対象に、4 種類の SNS アプリケーションを利用している際のセンサデータからデータセットを作成し、勾配ブースティング決定木アルゴリズムを用いて各 SNS アプリケーションを推定する機械学習モデルを作成した。k 分割交差検証により作成したモデルに対して Accuracy, Precision, Recall を算出し提案手法の有効性を示した。

1. はじめに

総務省の通信利用動向調査によると [1], 日本のスマートフォンの世帯保有率は、2011 年時点では 29.3%であったのに対し、2020 年時点では 86.8%に大幅に増加している。更に、インターネット利用機器としては、スマートフォンが 13 歳から 59 歳までの個人において 80%を超えており、6 歳未満及び 80 歳以上を除いた全ての世代において、最も高い使用率となっている。スマートフォンが広く普及した現代においては、スマートフォンに搭載された各種センサのデータは、多様な学問分野で確立された既存の方法論と組み合わせることで、新たな知見を獲得し得る可能性がある。

スマートフォン利用者を対象にしたセンシング可能なセンサデータとして、スマートフォンアプリケーションのスクリーンタイムデータが挙げられる。スクリーンタイムデータとは、スマートフォン利用者が使用した各アプリケーションの使用時間を示し、使用者の生活に密接に関連

していることからメンタルヘルスやフィジカルヘルス等の分野でデータの活用が期待される。

一方でスクリーンタイムデータは、ユーザプライバシーの観点からデータの取得に制限がある場合が多く [2], 容易に取得することが出来ないためデータ活用の機会を得づらいう問題がある。

そこで本研究ではスクリーンタイムデータと比較して取得制限が強く設けられていない加速度センサ及びジャイロスコープセンサデータに着目する。

スマートフォンアプリケーションは画面上のボタンやタブ等のユーザインタフェースによって構築されているが、同位置に存在するボタンをタップした際は類似した波形をもつデータになると想定される。一方、全く同一のユーザインタフェースをもつスマートフォンアプリケーションは少ない。また、各アプリケーションを使用する際は指の移動の規則性や端末を保持する角度等が変化するため、その動きは加速度センサ及びジャイロスコープセンサに反映されると考えられる。これらのセンサデータがスクリーンタイムデータとして代替可能であれば、スクリーンタイムデータの取得の機会を大幅に増幅できる。

そのため、本研究では加速度センサ及びジャイロスコープセンサといった、スマートフォンに標準的に搭載されている加速度センサデータ及びジャイロスコープセンサデータを活用し、機械学習を用いた利用中のスマートフォンアプリケーションを推定するモデルの構築及び評価を行うことを目的とする。

¹ 慶應義塾大学環境情報学部
Faculty of Environment and Information Studies, Keio University, Fujisawa, Kanagawa 252-0882, Japan

² 慶應義塾大学大学院政策・メディア研究科
Graduate School of Media and Governance, Keio University, Fujisawa, Kanagawa 252-0882, Japan

a) t19223tk@sfc.keio.ac.jp

b) hamachu@sfc.keio.ac.jp

c) wataruew@sfc.keio.ac.jp

d) slash@sfc.keio.ac.jp

e) jin@sfc.keio.ac.jp

本論文の構成は、2章ではスマートフォン搭載センサを活用した先行研究やスクリーンタイムデータを活用した先行研究、そしてアプリケーション利用履歴データの取得についての現状について述べる。3章では、本実験を実施するにあたって行った実装について述べる。4章ではデータセットを作成するための実験について述べ、5章では作成したデータセットの加工及び特徴量の算出、採用した機械学習アルゴリズムや評価指標について述べる。6章では実験結果及び考察を述べ、7章では提案手法の課題や展望をまとめ、8章にて本研究の結論を述べる。

2. 関連研究, 関連技術

本研究に関連する先行研究及び関連技術について説明する。

2.1 スマートフォン搭載センサを活用した研究

多くのスマートフォンには、加速度センサ、ジャイロスコプセンサ、磁気センサ、GPSセンサ、照度センサといった様々なセンサデバイスが搭載されている。

iPhoneでは2010年に発売されたiPhone4以降、全ての端末において加速度センサ及びジャイロスコプセンサが搭載されている。Androidにおいてもほとんどの端末に加速度センサが搭載され、多くの端末にジャイロスコプセンサが搭載されている。2021年のモバイル社会研究所の調査[3]によると、日本ではiPhoneの利用率は46.8%となり、日本の多くのスマートフォンユーザにおいて加速度センサ及びジャイロスコプセンサのデータが取得可能である。

スマートフォン搭載センサを活用した技術の一つに、Activity Recognitionがある。Activity Recognitionは、カメラ映像や加速度センサ、ジャイロスコプセンサなどを入力として受け取り、それらに対してどのような動作を行っているかを検出する技術であり、様々な分野で広く活用されている。Activity Recognitionの先行研究としては、Anguita et al.[4]があり、19から48歳の30人を対象にスマートフォンを腰に装着した状態で、(1) WALKING (2) WALKING_UPSTAIRS (3) WALKING_DOWNSTAIRS (4) SITTING (5) STANDING (6) LAYINGの6つのカテゴリの行動をしてもらい、その際に収集した加速度センサ及びジャイロスコプセンサデータを用いて各行動を推定するモデルを構築している。

本研究は、ユーザの操作するスマートフォン上での加速度センサ及びジャイロスコプセンサデータを入力とし、どのようなアプリケーションを利用しているか推定するものであり、Activity Recognitionに内包される分野であると考えられる。

Eren et al.[5]は、スマートフォンに搭載されている加速度センサ、ジャイロスコプセンサ及び磁力センサを用い

て、運転の安全度合いをそれぞれ評価した15人の自動車ドライバーを対象に、様々な天候で運転を行った際のデータを収集し、(1) ハンドル操作 (2) 加速操作 (3) ブレーキ操作 (4) 車線変更操作の4カテゴリの操作ごとに、安全運転及び危険運転のパターンを分類するモデルを構築した。15人中14人のドライバーにおいて、定性評価の結果と一致したとし、スマートフォンに搭載されている各種センサの応用性を明らかにしている。

2.2 スクリーンタイムデータを利用した研究

半導体技術の発展に伴い殆どの人がスマートフォンを所持している今日において、スクリーンタイムデータから得られる知見は大きな価値をもつ。

Sakurai et al.[6]は、18から39歳の2,543人、40から64歳の3,048人、65歳以上の2,985人を含む、合計8,576人に対して“LINE”、“Facebook”、“Twitter”、“Instagram”の4種類のソーシャルメディアでの投稿頻度及び閲覧の頻度と、メンタルヘルスの相関を調査し、“Facebookに頻繁に投稿するが頻繁にチェックは行わない40から64歳の人々において、個人の幸福度と関連がある”、“Twitterを頻繁に使用する全ての年齢層において、悩みや孤独感が強い傾向がある”、“Instagramを頻繁にチェックする18から39歳の人々において、健康で苦痛が少ない傾向にある”という結果を示した。

Royant-Parola et al.[7]は、中学1年生から中学3年生までの776人に対し、(1) 睡眠時間 (2) 休息時間 (3) コンピュータやスマートフォン、ゲーム等の画面を見ている時間と場所 (4) ソーシャルメディアの利用時間 (5) 就寝及び起床時刻 (6) 睡眠の質 (7) 日中の気分 (8) 日中の覚醒度についてのアンケート調査を行い、“寝室でスマートフォンまたは携帯電話を用いてソーシャルメディアを使用する学生は、睡眠不足になる傾向がある”、“ソーシャルメディアの利用が原因となる睡眠不足による日常生活への影響や気分への悪影響は、年齢が上がるほど増加する傾向にある”という結果を示した。

2.3 iOS及びAndroidにおけるスクリーンタイムデータの取得

2.2で述べた先行研究に代表されるように、スクリーンタイムデータは、メンタルヘルスやフィジカルヘルス等の分野でデータの活用が期待される。一方で、アプリケーションの起動時刻や終了時刻といった詳細な利用履歴を含むスクリーンタイムデータは、多くの場合プライバシーの問題からOSによって保護されている。

iOSにおいては、iOS12以降、公式で図1のようにアプリケーションのジャンルごとの総起動時間や起動回数等を可視化するScreen Time機能が追加された。しかし、同OSバージョンより、サードパーティ製の”どのアプリケー



図 1 iOS12 より提供されている Screen Time 機能の例

ションをどれだけ使ったかを表示”等を行うスクリーンタイムアプリケーションが制限された。iOS15にて、Screen-TimeAPIが公開され、ユーザのアプリケーション利用時刻の制限や、利用時間の上限等の設定を行うことが可能になった [2]。一方、アプリケーションごとの起動時刻や停止時刻などの詳細なデータは秘匿されており、開発者からは取得できない。

Androidにおいては、アプリケーションの起動履歴等を取得する場合は、ユーザ側から特別なアプリアクセス画面の内部にある“使用状況へのアクセス”という設定画面を経由して許可を与える必要があり、手動で明示的に許可を与えなければ取得できない。

3. データ収集システムの構築

本実験に必要なデータセットを作成するために、スマートフォンに標準搭載されている“加速度センサデータ”、“ジャイロスコプセンサデータ”、及びAndroid OSにて提供されている“アプリケーション利用履歴データ”の自動収集を行うバックグラウンドで動作するアプリケーションの開発を行った。

3.1 データ収集用 Android アプリケーション開発

学習に利用するデータを収集するため、“加速度センサデータ”、“ジャイロスコプセンサデータ”、“アプリ利用履歴データ”をバックグラウンドで収集し、端末内データベースに保存するAndroidアプリケーションの開発を行った。開発には、東京大学及びオウル大学が共同で開発を行っている、オープンソースモバイルセンシングフレームワークであるAWARE Framework[8][9]を利用した。

3.2 アプリケーション利用履歴収集モジュール開発

2.2で述べた通り、アプリケーション利用履歴データに

は様々な価値があることが期待されており、オープンソースフレームワークとしてアプリケーション利用履歴データの自動収集と保存を行うモジュールが求められる。

そこで、本研究において加速度センサ及びジャイロスコプセンサデータを自動取得、保存するために利用したAWARE Framework[8][9]に着目した。AWARE Frameworkにて提供されている共通基盤であるCoreフレームワークを利用することで、容易にアプリケーションに組み込むことが可能な、アプリケーション利用履歴データの自動収集と保存を行うプラグインを開発し、公開を行った。

データ取得においては、Android5.0以降に提供されているAPIであるUsageStatsManagerを利用し、Foreground-Serviceを用いてバックグラウンドで継続動作するように実装を行った。モジュールを呼び出す際には、

- (1) 利用履歴を収集するアプリケーションID
- (2) 起動/終了等の収集するアプリケーションイベントID
- (3) データ収集頻度(秒)
- (4) バックグラウンド動作を行う際の通知タイトル

を指定するように実装し、指定した時間ごとに、指定したアプリケーション及びイベントデータ、そしてそのUnixタイムスタンプがSQLiteデータベース形式で保存される。

また、AWARE Frameworkにて提供されているサーバマイクロサービスであるAWARE Microが動作するサーバのエンドポイントを指定することで、自動的に端末に保存したデータをAWARE Microサーバにアップロードされるように実装を行った。

プラグインの開発には主にAndroidアプリケーションの開発に用いられるKotlin1.5を利用し、公開にはAndroidパッケージリポジトリであるJitPackを利用することで、オープンソースビルド自動化システムであるGradleを用いて公開したプラグインURLを1行記述するだけで、プラグインの利用を可能とした。

プラグインの利用にあたっては、上記の通りにGradleを利用しJitPackのURLを記述した上で、収集したいアプリケーションIDやイベントID、収集頻度を指定し、プラグインのインスタンスに対してStartメソッドを呼び出さず、自動的にデータのストリーミングが始まり、端末内データベースに保存される。

開発したプラグインのソースコード及び利用方法は以下のGitHubリポジトリ*1にて公開を行った。

4. 実験

実験を行うにあたっての実験設定についてまとめる。

*1 https://github.com/KarasawaTakumi0621/aware_appusage-plugin

4.1 データ収集及びデータセットの作成

アプリケーションの利用時のスマートフォンの動きには，“Instagram では，ストーリー機能を多く利用している”，“Twitter では，テキストの閲覧よりも画像や動画の閲覧を多く行う”，“前の画面へ遷移する際は，ナビゲーションバーのタップではなく画面横スワイプジェスチャーを利用する”などの，ユーザごとの使い方の偏りや操作の癖があり，その差異は収集する加速度センサデータ及びジャイロスコopセンサデータに反映されると考える．そのため，データセットに含まれるユーザごとの差異がどれほど多く反映されるかを明らかにするべく，データセットとして第一著者のみのデータと，15歳から45歳の男女10名から構成されるデータの2通りのデータを収集し，比較を行う．

データを収集した際の設定及び環境として，端末はAndroid Pixel 5a を利用し，各種センササンプリング周波数は100hzとした．収集の際は，PCとPixel 5aを1mのUSBケーブルで繋いでいる状態で行った．推定するアプリケーションや利用者の状態として，(1) Instagram (2) Twitter (3) Facebook (4) TikTok (5) 何もしていない状態 (Still) の5つの状態を想定した．各アプリケーションは似たような特性を持つ．さらに実環境を想定し“何もしていない状態 (Still)”も含めたデータセットを作成した．

10名の被験者に対しては対面でデータ収集を行った．用意した端末及びアプリケーションがバックグラウンドで動作している状態で，上記SNSについて，自由な順番で各アプリケーションを連続して10分程度使用するよう指示し，操作内容については自由に操作するように告知した．休憩など，アプリケーションを利用していない時間は，アプリケーションを閉じるように指示し，“何もしていない状態 (Still)”としてラベル付されたデータが収集されるようにした．また，なるべく多くのアプリケーションの利用経験がある被験者を集めたが，利用経験がないアプリケーションがある被験者が数名存在した．それらの被験者に対してはアプリケーションごとに複数のダミーアカウントを用意し，あらかじめ軽く操作してもらいアプリケーションのユーザインタフェースを知った上で，データ収集を実施した．表1にて，被験者の対象アプリケーションの利用経験の内訳を示し，表2，表3にて，最終的に収集したデータセットの内訳を示す．

表1 被験者の対象アプリケーションの利用経験の内訳

| | Instagram | Twitter | Facebook | TikTok |
|---------|-----------|---------|----------|--------|
| 初めて利用 | 0 | 0 | 3 | 2 |
| 利用経験がある | 10 | 10 | 7 | 8 |

5. 特徴量の算出と機械学習モデルの構築

5.1 特徴量の算出

収集したデータセットに対して，特徴量の算出及び推定

表2 (データセット1(1名)データ量)

| | レコード数 | 分数換算 |
|-----------|--------|------|
| Still | 117126 | 19分 |
| Instagram | 116758 | 19分 |
| Twitter | 129645 | 21分 |
| Facebook | 107609 | 18分 |
| TikTok | 128619 | 21分 |

表3 (データセット2(10名)データ量)

| | レコード数 | 分数換算 |
|-----------|--------|------|
| Still | 121551 | 20分 |
| Instagram | 516607 | 86分 |
| Twitter | 523548 | 87分 |
| Facebook | 485730 | 80分 |
| TikTok | 526397 | 87分 |

モデルの構築をおこなった．データの加工には，Python3.7及びpandas[10]を用い，加速度センサ及びジャイロスコopセンサのTimestampを基にデータフレームを作成し，3.2にて設定し取得した，アプリケーションID及びアプリケーションを開いたイベントのTimestamp，アプリケーションを閉じたイベントのTimestampをもとに，アプリケーション名をラベルとしてラベル付けを行った．作成したデータフレームから，特徴量の算出をおこなった．特徴量には加速度センサのx軸，y軸，z軸，ジャイロスコopセンサのx軸，y軸，z軸それぞれに対して中央値，標準偏差，振幅，周波数，位相を100レコード=1秒間毎に算出した．

5.2 モデル選択

機械学習ライブラリにはscikit-learnを利用し，機械学習アルゴリズムには，変数間の相互作用が反映される，特徴量の寄与度を算出できる等の特徴を持つ勾配ブースティング決定木(GBDT)[11]を採用した．推定結果の評価方法として，K分割交差検証を用いてデータセットを5つのサブセットに分割し予測の正確さを表すAccuracy，予測したもののうち正しかった割合を表すPrecision，取りこぼすことなく予測することができた割合を表すRecallを算出した．今回のデータセットでは，各アプリケーションのデータ割合が表2,3に表されるように偏りが少ないため，モデルの性能を比較するにはAccuracyについて注目するべきであると考え．また，それぞれのアプリケーションごとにどれだけ推定が可能であったかを評価，比較するため，アプリケーションごとのRecall及びPrecisionをどちらも考慮できるF値を算出し，比較する．

6. 実験結果及び考察

データセット毎の精度を表4に示す．

データセット1のみを用い，“Instagram”，“Twitter”，“Facebook”，“TikTok”及び“何もしていない状態”につい

表 4 データセット毎の精度及び差分

| | Accuracy | 平均 Precision | 平均 Recall |
|----------|----------|--------------|-----------|
| データセット 1 | 0.7483 | 0.7695 | 0.7511 |
| データセット 2 | 0.5617 | 0.6047 | 0.5688 |
| 差分 | 0.1399 | 0.0964 | 0.1296 |

ての学習と推論を行った結果を図 2, データセット 2 のみを用いて同様に学習と推論を行った結果を図 3 に示す. データセット及びデータセット 2 においての, アプリケーションごとの F 値及びその差分を表 5 に示す. また, 推定に寄与した特徴量を表す Feature Importance をそれぞれ図 4, 図 5 に示す.



図 2 データセット 1 についての Confusion Matrix.
0:Still,1:Instagram,2:Twitter,3:Facebook,4:TikTok が対応する.

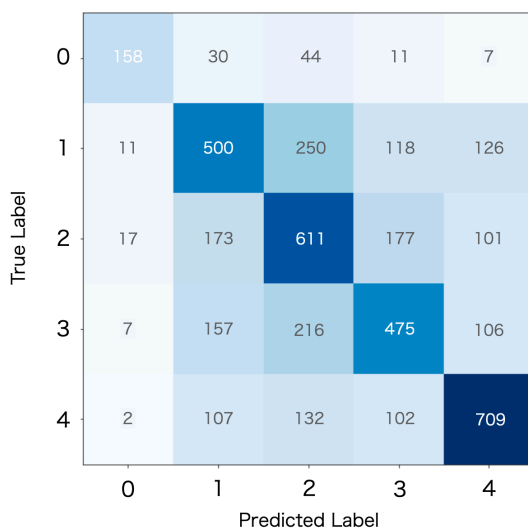


図 3 データセット 2 についての Confusion Matrix.
0:Still,1:Instagram,2:Twitter,3:Facebook,4:TikTok が対応する




図 4 データセット 1 を利用したモデルでの Feature Importance 上位 5 項目




図 5 データセット 2 を利用したモデルでの Feature Importance 上位 5 項目

6.1 第一著者のみのデータを用いた推定結果

表 4 で示した通り, 第一著者がアプリケーションを利用した際の計 98 分のデータが含まれるデータセットを用いたモデルでは, Accuracy が 0.7483 と高い結果を示した. また, 表 5 で示した通りに F 値を比較すると, “何もしていない状態”が最も高く, 0.9870 を示した. これは, データ収集を行った環境が自室であり, 操作を行っていない時間の動作が単一であったためであると考えられる. アプリケーションの中で最も高い F 値を示したのは, TikTok であり, 0.7733 であった. 一方, アプリケーションの中で最も低い F 値を示したのは Instagram の 0.5402 であった.

6.2 複数人のデータを用いた推定結果

表 3 で示した通り, 10 名において各アプリケーションを利用した際の計 360 分のデータが含まれるデータセットを用いたモデルでは, Accuracy が 0.5617 を示した. また, 表 5 で示した通りに F 値を用いて推定の精度を比較すると, “何もしていない状態”が最も高く, 0.7101 を示した. アプリケーションの中で最も高い F 値を示したのは TikTok であり, 0.6749 であった. 一方, アプリケーションの中で最も低い F 値を示したのは Instagram の 0.5070 であった.

6.3 推定結果の比較及び考察

実験結果から, 第一著者のみのデータを用いたデータセット 1 では, 0.7483 の Accuracy を示していたのに対し, 10 名のデータを用いたデータセット 2 では Accuracy が 0.5617 と, 0.1399 の精度の低下が見られた.

また, 表 5 で示した通り, アプリケーションごとに F 値を算出した結果, データセット 1 及びデータセット 2 の両方にて, (1) Still (何もしていない状態) (2) TikTok (3) Twitter (4) Facebook (5) Instagram の順に, 推定精度が高いという結果が出た. アプリケーションの中で TikTok が最も高い正解率で推定できた理由として, TikTok のユーザインタフェースが同様の長さの画像を視聴し, スワイプで次の

表 5 アプリケーションごとの F 値とその差分

| | Still | Instagram | Twitter | Facebook | TikTok |
|----------|--------|-----------|---------|----------|--------|
| データセット 1 | 0.9870 | 0.5402 | 0.6370 | 0.5948 | 0.7733 |
| データセット 2 | 0.7101 | 0.5070 | 0.5240 | 0.5151 | 0.6749 |
| 差分 | 0.2769 | 0.0332 | 0.113 | 0.0797 | 0.0984 |

動画を視聴するといった設定であるために、使い方による個人差が比較的小さくなったためだと考える。

そして、図 2, 3 の Confusion Matrix を見ると、データセット 1 及びデータセット 2 両方の場合において、Twitter, Instagram, Facebook の 3 種が多く混同されている。原因として、いずれのアプリケーションも短文のテキスト、画像、動画を視聴するアプリケーションであり、同様の操作が多いためであると考えられる。特にテキストを読む速さや画像、映像を見る頻度などについて、ユーザごとの使い方の差異が大きく表れるため、複数被験者のデータを用いて作成したデータセット 2 において精度が低下した原因であると考えられる。

6.4 作成したモデルの Feature Importance に関する考察

学習を行ったモデルの Feature Importance を算出し可視化した結果、データセット 1 を利用した場合 (図 4) とデータセット 2 を利用した場合 (図 5) のいずれも加速度センサにおける y 軸及び z 軸の平均値 (median_accel_y, median_accel_z) が特に寄与していることがわかった。スマートフォンに搭載されている加速度センサの軸は、図 6 のように、画面側を正面として左右軸が x 軸となり、上下軸が y 軸、奥行きが z 軸となる。これらの 2 つの特徴量が重要となった理由として、今回の実験にて利用した 4 種類のアプリケーションのいずれも、上下のスクロール (y 軸の変化) 及びタップ動作でのコンテンツ選択 (z 軸の変化) によるものと推察できる。

7. 課題と今後の展望

7.1 本研究の課題

本研究の課題としては 2 点挙げられる。

1 点目は汎化性能に大きく欠けてしまっている点である。今回の実験では 4 種類のアプリケーションとそれ以外の状態の 5 種類を推定及び検証を行ったが、世界中に存在するアプリケーションの数は数百万を超え、全てをそれぞれ識別することは不可能であるといえる。

2 点目は、今回の推定手法はユーザインタフェースに大きく依存してしまうために、同様のユーザインタフェースを持つアプリケーションの推定が難しい点である。アップデートによるインタフェース変更や、端末サイズの差、OS ごとのユーザインタフェースの違いによって精度がさらに低下してしまう可能性がある。




図 6 [12] より引用。スマートフォンにおける加速度センサの軸の例

7.2 今後の展望

今後の展望として、特定のアプリケーションの検出に絞ったモデルの作成を行うことを目標とする。スマートフォンアプリケーションは数多く存在し、かつユーザがどのアプリケーションをインストールしているか知ることは難しい。既存研究 [13] では SNS の種類によってメンタルヘルスとの関係性が異なることがわかっており、データとして大きく価値があると推測できる各 SNS にのみ特化したモデルを作成するなどのアプローチによって、新たなセンシング基盤としてデータの活用が可能だと考える。

また学習の際に用いる特徴量を増やすことも検討している。本稿では加速度センサ及びジャイロセンサのみを用いて推定をおこなっているが、アプリケーションごとに負荷の大きさが違う点などに着目し、CPU の使用率やバッテリーの使用量、ネットワーク通信量など今回使用しなかったデータを用いることで推定精度が向上する可能性がある。

より多くの被験者のセンシングデータからモデルを再度構築し、精度の変化について検証を行うことも検討している。今回の実験では、男女 10 名に対して PC と実験用スマートフォンを接続した状態でデータを取得しデータセットの作成を行ったが、スマートフォンや各種アプリケーションを利用する状況は歩行中や公共交通機関での移動中など様々なコンテキストが想定される。また、テキストを読む速度やスワイプ速度といった、ユーザごとの操作特性を踏まえたモデルを構築することで、アプリケーションご

との操作の差異をより明確に反映した推定が行えると考えられている。今後はより多くのデータをもとにモデルを構築することで、センサデータの応用可能性の検討を進める。

8. 結論

本研究では、多くの人が利用するスマートフォンにおけるセンシング可能なデータとして、アプリケーションの利用時刻や利用時間等を表すスクリーンタイムデータの取得難度の高さに着目し、加速度センサ及びジャイロスコープセンサデータのみから利用中のアプリケーションを推定することで、センサデータの新たな応用可能性の検討を行った。本研究の目的である新たなセンシング基盤としての活用の可能性については、10人における4種類の利用アプリケーション及び何もしていない状態の計5種類の動作の推定においてPrecisionが0.5617の評価値であり、取得ハードルを回避した新たなセンシング基盤としての活用の可能性を示した。一方、大量のアプリケーションが混在して利用される実社会において、加速度センサデータ及びジャイロスコープセンサデータのみを用いた推定には限界があると考えられる。よって今後の展望として、データセットの規模を大きくする他、CPU使用率やバッテリーの使用量、ネットワーク通信量など使用しなかった他のデータを活用しモデルの精度向上に取り組む。

謝辞 本研究は、JST, CREST, JPMJCR19A4の支援を受けたものです。本研究は、JSPS 科研費 JP21K11853の助成を受けたものです。本研究は、独立行政法人日本学術振興会の「日中韓フォーサイト事業」(課題番号: JPJSA3F20200001)の助成を得た。

参考文献

- [1] 総務省. 令和2年通信利用動向調査. <https://www.soumu.go.jp/johotsusintokei/statistics/statistics05a.html> (accessed 2022-05-10).
- [2] WWDC2021. Meet the screen time api. <https://developer.apple.com/videos/play/wdc2021/10123/> (accessed 2022-05-10).
- [3] モバイル社会研究所. モバイル社会白書2021年版. <https://www.moba-ken.jp/whitepaper/wp21.html> (accessed 2022-05-10).
- [4] D. Anguita, Alessandro Ghio, L. Oneto, Xavier Parra, and Jorge Luis Reyes-Ortiz. A public domain dataset for human activity recognition using smartphones. In *ESANN*, 2013.
- [5] H. Eren, S. Makinist, E. Akin, and A. Yilmaz. Estimating driving behavior by a smartphone. pp. 234–239, 2012.
- [6] Ryota Sakurai, Yuta Nemoto, Hiroko Mastunaga, and Yoshinori Fujiwara. Who is mentally healthy? mental health profiles of japanese social networking service users with a focus on line, facebook, twitter, and instagram. *Plos one*, Vol. 16, No. 3, p. e0246090, 2021.
- [7] S Royant-Parola, V Londe, S Tréhout, and S Hartley. The use of social media modifies teenagers' sleep-related behavior. *Encephale*, Vol. 44, No. 4, pp. 321–328, September 2018.
- [8] Denzil Ferreira, Vassilis Kostakos, and Anind K Dey. Aware: mobile context instrumentation framework. *Frontiers in ICT*, Vol. 2, p. 6, 2015.
- [9] Yuuki Nishiyama, Denzil Ferreira, Yusaku Eigen, Wataru Sasaki, Tadashi Okoshi, Jin Nakazawa, Anind K Dey, and Kaoru Sezaki. ios crowd-sensing won't hurt a bit!: Aware framework and sustainable study guideline for ios platform. In *International Conference on Human-Computer Interaction*, pp. 223–243. Springer, 2020.
- [10] pandas.pydata.org. <https://pandas.pydata.org> (accessed 2022-05-10).
- [11] scikit learn.org. <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html> (accessed 2022-05-10).
- [12] Apple Inc. Getting raw accelerometer events. https://developer.apple.com/documentation/coremotion/getting_raw_accelerometer_events.
- [13] Kira E Riehm, Kenneth A Feder, Kayla N Tormohlen, Rosa M Crum, Andrea S Young, Kerry M Green, Lauren R Pacek, Lareina N La Flair, and Ramin Mojtabai. Associations between time spent using social media and internalizing and externalizing problems among us youth. *JAMA psychiatry*, Vol. 76, No. 12, pp. 1266–1273, 2019.