

日常生活を反映したスマートフォンログに基づく well-being 推定

濱谷 尚志^{1,a)} 山本 直樹¹ 河田 隆弘¹ 荒川 大輝¹ 檜山 聡¹ 姚 文昊² 上西 康平² 太田 順²
寺澤 悠理³ 沖村 宰³ 前田 貴記³

概要: 近年スマートフォンの普及が進んでおり、スマートフォンを用いたヘルスケア技術に期待が高まってきた。スマートフォンは日々ユーザが持ち歩き、使われるものであるため、ユーザの well-being を反映することが期待できる。本研究では、スマートフォン搭載センサや利用履歴より得られる情報に基づき、利用者の well-being を推定する手法を提案する。スマートフォンを用いた well-being 推定の可能性を検証するため、本研究では所属や職種を問わない 90 名の参加者より収集したログデータ、および 5 種類の well-being 指標の調査票に基づき、5 種類の well-being 指標の推定の実現可能性を明らかにした。

キーワード: スマートフォン, ヘルスケア, well-being

1. はじめに

我が国は超高齢社会を迎え、男女とも平均寿命が世界最高水準に達するまでに至っており、病気の予防はもちろんのこと、健康寿命や生活の質により多くの関心が寄せられている。病気や生活の質に関連して、WHO 憲章^{*1}では “Health is a state of complete physical, mental and social well-being and not merely the absence of disease or infirmity.”, すなわち、健康が、身体面、精神面、社会面におけるすべての well-being (良好性) の状況を指し、単に病気、病弱でない事ではないことを宣言しているように、今後の日本では、病気を予防するだけでなく、健康な人においても身体面、精神面、社会面において well-being である状態を維持し、0 次予防を行っていくことが重要となっている。

well-being の状態を計るため、これまでに数々の well-being の指標、および計測するための調査票が提案され、日本国内での実施のために和訳が行われてきた。例えば Subjective Well-Being Scale (SWBS) [1] では、15 問の設問に対して 4 個の選択肢の最も自身の状態に近いと考える選択肢を選ぶことで、主観的 well-being 指標を数値化できる。このように、well-being の指標を計測するためには

測定対象者自身が調査票に回答する必要があり、継続的に well-being の計測を実施することは負担となりえる。

近年、スマートフォンの普及率は世界的に増大してきており、スマートフォンを用いたデジタル・ヘルスケアの技術への関心が高まってきている。スマートフォンはジャイロセンサやステップ検知の仕組みなどを搭載しており、ユーザの身体的な動きを知ることができるだけでなく、スマートフォンを通じたユーザのサイバー空間上での活動 (例えば SNS での他者との交流など) を利用履歴を通じて大まかに把握することができる。そのため、スマートフォンにより得られる各種ログデータに基づき利用者の心理的なストレスの推定などが行われてきた [2]。Well-being に近い指標として知られる QoL (Quality of Life) についても、スマートフォンと、腕装着型ウェアラブルデバイスを用いて位置情報、加速度、心拍感覚、皮膚体温を取得し推定する手法が提案されている [3]。このように、スマートフォン内蔵センサやスマートフォンで収集可能なログデータを中心としたデータの活用により、ユーザの内面的な健康状態を推定できることが示されてきている。

こういった先行研究の状況を踏まえて、著者らはこれまでにスマートフォン取得データに基づく well-being 推定の可能性を検討し、推定モデルにおける精度として、F 値 (F-measure) が平均で 0.7 を上回ることを確認し、スマートフォンを用いた well-being 推定の実現可能性を確認した [4]。一方で、著者らの先行研究では学生を中心とした大学関係者 14 名でデータ収集およびモデル構築・評価

¹ 株式会社 NTT ドコモ (NTT DOCOMO, INC.)

² 東京大学 (The University of Tokyo)

³ 慶應義塾大学 (Keio University)

a) takashi.hamatani.rt@nttdocomo.com

*1 1946 年 7 月にニューヨークで作成され、1948 年 4 月 7 日に効力発生。日本では 1951 年 6 月 26 日に条約第 1 号として交付された。

を行っており、大学関係者以外へ手法を適用する際に、生活様式の違いなどによりスマートフォンのログ傾向が異なり、その結果推定精度が低下する可能性がある。そこで本研究では、多様なユーザに対しスマートフォンログを用いて well-being の推定を行うため、著者らの従来手法を拡張する。生活様式の違いはスマートフォンを持ち歩く人の動きや、スマートフォンの使い方に表れると考えられる。そのため、スマートフォンのログデータに基づいてフィジカル空間での活動、およびサイバー空間での活動パターンを特徴量化することで生活様式の違いを考慮したモデル構築を検討する。フィジカル空間での活動は加速度や位置情報といった基本的なログにより考慮可能である一方で、サイバー空間でのユーザの行動パターンを考慮することが難しい。そこで提案手法では、Android スマートフォン上で取得できるアプリケーションのログに対して Google が定めるカテゴリを適用し、カテゴリ単位で網羅的にユーザのアプリケーション起動、すなわちサイバー空間での活動の特徴量化することで、多様な日常生活を送るユーザに対しても適用可能な well-being 推定モデルの構築を検討する。

実際に、多様な日常生活を想定して提案手法を評価するため、性別、年代、職種を問わず募集した 90 名の研究参加者より収集したスマートフォンのログデータ、および 5 種類の well-being の調査票を用いて推定モデルを構築し well-being 推定手法の精度評価を行った。その結果、各調査票に対して F 値 (F-measure) で 0.821 から 0.910 の間の精度で指標の変化を推定可能であることを確認し、スマートフォンを通じて受動的に得られるログのみを用いる場合においても利用者の well-being の変動を捉えられる見込みを得た。

本研究における貢献は次のとおりである。

- 多様なユーザに対してもサイバー空間上での活動を抽出するため、カテゴリ単位でアプリ利用を集約し特徴量化する方法を提案し、推定モデルの評価を通じて有効性を確認した。
- 実際に性別、年齢、職種の観点で多様なユーザ群に対して、提案手法により著者らの従来手法と同等以上の精度で well-being の変動を推定できることを明らかにした。

2. 関連研究

スマートフォンには制御のために加速度センサや GPS など多数のセンサが搭載されており、ユーザの行動を受動的に取得することが可能である。スマートフォンの高い普及率も相まって、スマートフォンを活用したデジタル・ヘルスケア技術への関心が高まってきている。スマートフォンの強みとして、スマートフォンを媒介したソーシャルネットワークサービスの利用や、商品購入や決済の利用、動画サービスの利用など、ユーザのライフスタイルに関係

するアプリケーションの起動履歴を取得できることが挙げられる。先行研究では、スマートフォンで得られる利用者の位置情報の軌跡から depression (抑うつ傾向) の推定 [5]、ソーシャルメディアの利用傾向を通じた心理的なストレス推定 [6] などが実施されている。

さらに、複数のログを組み合わせることによりユーザの多角的な行動傾向を踏まえた心理状態の推定も行われている。Fukazawa らはスマートフォンで得られるログに基づき、ユーザの不安度 (anxiety level) の変化を推定する取り組みを行っており、加速度や照度、アプリケーションの利用ログを基に、複数のログ種別から得た特徴量を組み合わせることで推定精度を高められることを示している [7]。この研究では、アプリケーションのログの特徴量化において、ソーシャルネットワーク、web ブラザ、メール、エンターテインメントの 4 つの軸による特徴量化を行っており、他のアプリケーションのログの特徴量化が実施されていない。Amenomori らは、スマートフォンと、腕装着型ウェアラブルデバイスを用いて位置情報、加速度、心拍感覚、皮膚体温を取得し、QoL を推定する取り組みを行っている [3]。この研究では特徴量としてユーザの動きに関するものや、生体情報の反応が用いられており、サイバー空間上でのユーザの活動までは考慮されておらず、アプリケーションログのような情報を組み合わせることで推定精度を高められる可能性がある。

本研究チームにおいても、これまでスマートフォンの各種ログデータを時空間的に特徴量化することで心理的なストレス状態を推定する取り組み [2] や、スマートフォンを用いた well-being 推定の実現可能性を検討してきた [4]。著者らの先行研究 [2]、[4] では同一企業の勤務者や、同一大学の大学関係者よりデータを収集してモデル構築・評価を行っており、モデル構築を行ったユーザと異なる属性のユーザに対して手法を適用する際に、生活様式の違いなどによりスマートフォンのログ傾向が異なり、その結果推定精度が低下する可能性があることが課題であった。この課題に対し、本研究では多様なユーザの生活様式を想定した well-being の推定モデルを構築することを目的とし、ユーザの生活様式をより幅広く捉えるためにアプリケーションの利用に関して、Google Play Store で定義されるアプリケーションのカテゴリを網羅的に利用して特徴量を設計し、提案手法を評価するために実際に性別、年代、職種を問わず募集した 90 名の研究参加者から収集したデータに基づき、提案手法の有効性を検証する。

3. well-being の推定手法

3.1 問題設定

本研究ではスマートフォンで収集した各種ログに基づき、利用者の well-being を推定することを目的とする。具体的には、スマートフォンから得られるログデータに基づ

き、利用者の行動パターンを表すための特徴量を抽出し、機械学習モデル構築における説明変数とするとともに、利用者自身が回答した well-being の調査票を目的変数とすることで、教師あり機械学習により well-being の推定モデルを構築する。

著者らの先行研究 [4] により well-being の指標は週単位でも変動することを確認したため、本研究においても 1 週間ごとに 5 種類の well-being 調査票を研究参加者自身により回答してもらいデータを収集する。その際に、回答する時間帯や回答する曜日による影響を最小化するため、定められた曜日の午後に well-being の調査票の回答が行われた。このように収集した 1 週間ごとの各種 well-being 指標について、1 週間ごとの指標を比較することにより変動値を求め、推定モデル構築における説明変数とする。調査票により定量化される well-being の数値自体はユーザによってベースラインとなる値が異なり得るものの、well-being の指標が低下するときに表れる行動のパターンは、異なるユーザにおいても共通するパターンが存在するという仮説のもと、1 週間ごとの well-being 指標の変動を目的変数として推定する。以降の各節では取得するスマートフォンログ、説明変数、目的変数およびモデル構築手法について述べる。

3.2 スマートフォンログ

本研究では Android 端末でスマートフォンログを収集するアプリケーションを用い、表 1 に示すスマートフォンログを収集する。取得するログは大別すると、(1) 端末や身体の動きや活動に関するもの：加速度、角速度、端末の傾き、歩数、activity recognition、位置情報、(2) 端末を使った活動に関するもの：バッテリーの残量、充電状態、画面の点灯及び消灯、アプリの起動および終了、イヤホンの着脱、(3) 利用者周辺の環境に関するもの：照度、気圧、Wi-Fi 接続状態、周辺 Wi-Fi 情報の 3 種類に分けられる。上記のログを用いて、本研究では機械学習モデルに入力する説明変数を抽出する。

3.3 説明変数（特徴量）の抽出

3.1 節で述べた通り、本研究では 1 週間ごとの well-being 指標の変動を推定するため、説明変数も 1 週間分のスマートフォンのログを用いるものとする。1 週間分のログに対して、各曜日ごとのログより生成した 1 日単位の特徴量と、7 日分のログより生成した 1 週間単位での特徴量を合わせて機械学習モデル構築のため固定長の特徴量ベクトルとする。具体的な特徴量として、前節で定めた上述の 3 種類のログ種別に対し以下の特徴量を生成する。

フィジカル活動特徴量：端末や身体の動きや活動に関するログによって得られるより統計量を求めることにより計算する。加速度、角速度、傾きについては平均値、偏差、最

表 1 本研究で取得するスマートフォンログの一覧

種別	取得内容	取得頻度
加速度	x, y, z 軸の成分 [m/s^2]	1 秒毎
角速度	x, y, z 軸に対する成分 [rad/s]	1 秒毎
端末傾き	方位角, 傾斜角, 回転角 [rad]	1 秒毎
歩数	5 分間の合計歩数	5 分毎
activity recognition	Activity Recognition API で取得した情報 (歩行, 静止など)	5 分毎
位置情報	端末が測位した緯度, 経度, 高度	5 分毎
バッテリー残量	端末バッテリーの残量値 [%]	5 分毎
充電の開始・終了	充電器が着脱された時刻	随時
画面の点灯・消灯	画面が点灯, 消灯した時刻	随時
アプリの起動・終了	アプリが起動, 終了した時刻	随時
イヤホンの着脱	イヤホンが着脱された時刻	随時
周辺照度	周辺照度	5 分毎
気圧	周辺気圧	5 分毎
Wi-Fi 接続状態	Wi-Fi の有効/無効の状態, アクセスポイントへの接続状態, 接続しているアクセスポイントの SSID	5 分毎
周辺 Wi-Fi 情報	端末周辺アクセスポイントの SSID の一覧	5 分毎

大値などを求める。歩数については一日または一週間の合計値を求め、activity recognition については各種 activity の割合を算出する。加速度などのセンサの値を観察することで、ユーザが静止しているか、移動しているかを問わず身体の動きを検出することができる。さらに、歩数や activity recognition を利用することでユーザの実際の活動量および移動方法を考慮することができる。

サイバー活動特徴量：端末を使った活動に関するログにより得られる統計量を求めることにより計算する。バッテリー残量については得られる値の平均値、偏差、最大値などを求める。充電やイヤホンの着脱については回数を集計する。画面の点灯・消灯については回数、および点灯時間の平均、偏差、最大値などを求める。アプリケーションの起動・終了については、アプリケーションの識別子ではなく Google Play Store で定義されるカテゴリ単位で集計した上で、起動回数、起動時間と、アプリカテゴリ全体に対して占める割合を計算する。画面の点灯回数や点灯時間を観察することで、サイバー空間での活動の量的側面を数値化するとともに、バッテリーの変化量は利用するアプリケーションによっても影響を受けるため、サイバー空間での活動の質的側面を考慮することができる。また、充電履歴によりサイバー空間での活動への意欲を、イヤホンの着脱履歴によりサイバー空間活動の中でも音楽を伴うものへの没入度を定量化することができる。さらに、カテゴリ単位でアプリケーションのログを集計し、各カテゴリの割合として定量化することでユーザのアプリ利用パターンをベクトル化することができる。

表 2 本研究で利用する特徴量の一覧

種別	内容	次元数
(1) フィジカル活動特徴量		
加速度	3 軸それぞれの加速度の平均, 標準偏差, 最大値, 最小値, 最大最小の差, 2 軸の相関係数, 3 軸のベクトルの大きさの平均値 (これらを重力加速度成分有り, 無し の 2 通りで計算)	342
角速度	3 軸それぞれの加速度の平均, 標準偏差, 最大値, 最小値, 最大最小の差, 2 軸の相関係数,	171
端末傾き	3 軸のベクトルの大きさの平均値	171
歩数	24 時間の歩数合計	9
activity recognition	on vehicle, on bicycle, walking, running, on foot, still, tilting, unknown の割合, および on vehicle + on bicycle, walking + running + on foot の割合	90
位置情報	緯度, 経度, 高度の最大最小の差, 緯度経度最大と最小点で描画される領域面積, 最も離れた 2 座標の距離, 一日の総移動距離	54
(2) サイバー活動特徴量		
バッテリー残量	24 時間の平均, 標準偏差, 最大値, 最小値, 最大最小の差	45
充電の開始・終了	24 時間の実施回数	9
画面の点灯・消灯	24 時間のオン回数, オフ回数, オン時間の平均, 標準偏差, 最大, 最小	54
アプリの起動・終了	24 時間のアプリ起動回数, 起動時間, 全起動時間に占める時間割合 (合計 64 種類のアプリカテゴリおよび全アプリに対して計算)	1755
イヤホンの着脱	24 時間の接続回数	9
(3) 周辺環境特徴量		
周辺照度	24 時間の平均, 標準偏差, 最大値, 最小値, 最大最小の差	45
気圧	24 時間の平均, 標準偏差, 最大値, 最小値, 最大最小の差	45
Wi-Fi 接続状態	24 時間の Wi-Fi 設定オン率, 任意のアクセスポイント (AP) への接続率, 接続した AP 数, 最も接続した AP への接続率	36
周辺 Wi-Fi 情報	24 時間の観測 AP 数 (重複あり, 重複なしの 2 通り)	18

周辺環境特徴量: 利用者が置かれた周辺の環境に関するログにより得られる統計量を求めることにより計算する。周辺照度, 気圧については得られるスカラ値の平均, 偏差, 最大などを求める。位置情報については, ユーザの自宅と推定された地点に対する相対的な緯度, 経度および高度の変化量, および一日の移動軌跡により求める総移動距離, 最も離れた 2 地点間の距離, および緯度経度最大の点と緯度経度最小の点により描かれる領域の面積を特徴量とする。Wi-Fi 接続情報では, Wi-Fi 自体のアクティブ設定率および何らかのアクセスポイント (AP) への接続率, および接続した AP の総数と最も接続した AP へ接続した割合を求める。周辺 Wi-Fi 情報は, 観測した AP の数について重複ありの条件と重複なしの条件で集計した総数を特徴量化する。周辺照度, 気圧情報により, 利用者が置かれた周辺環境の特性を考慮することができる。位置情報は利用者の移動パターンや移動頻度を考慮するために作成した。Wi-Fi への接続は昨今のスマートフォン利用において重要となっており, Wi-Fi がある環境にいるか, そうでない環境にいるかを考慮するために用いる。また, 周辺 Wi-Fi 情報については, 接続しなくても得られるものであり, 都市部ほど多くの AP が配置されていることから, 多くの AP を観測する可能性が高く, 大まかに都市部や商業地帯にいるか, そうでない地帯にいるかを考慮できる可能性がある。

以上の特徴量について, 提案手法では合計 2853 次元の

特徴量を作成し, 後述の機械学習モデルの構築を行う。特徴量の詳細を表 2 に示す。

3.4 目的変数: well-being 指標の変動値

本研究では表 3 に示す well-being の調査票を利用し教師あり機械学習のための教師データを収集する。表中の指標はいずれも well-being に関連する指標であるが, 時間軸や観察する well-being の側面が異なっているため, 本研究では 5 種類の well-being 推定モデルを作り分け, 推定結果を比較することで推定可能な well-being を明らかにすることも目的としている。表に示す 5 種類の調査票を研究参加者自身が毎週回答し得られた回答結果を集計した well-being の点数の系列 y_i に対して, 連続する 2 週間における変動値について, 点数が下がった場合とそうでない場合の 2 クラス分類を行う。具体的には, ある週の well-being の点数 y_i , その前週の well-being の点数 y_{i-1} に基づき, 2 値のラベル \hat{y}_i を以下の通り定める。

$$\hat{y}_i = \begin{cases} 1 & \text{if } (y_i < y_{i-1}) \\ 0 & \text{otherwise} \end{cases}$$

この方法により, 得られたラベルの 1 は well-being の指標の数値が悪化することを示し, 0 は well-being の指標が変化しない, または向上することを示している。

表 3 取得した well-being 指標の一覧

名称	概要	設問数
PANAS(the positive and negative affect schedule)[8]	現在の気分, 感情状態や一定期間における頻度を評価する	20
SUBI(the subjective well-being inventory)[9]	心理的, 身体的, 社会的側面からの well-being をポジティブ・ネガティブの二つの側面から評価する	40
FS(flourishing scale)[10]	関係, 自尊心, 目的, 楽観などの重要な分野で回答者が自己認識した成功の簡単な 8 項目の要約尺度	8
SWLS(the satisfaction with life scale)[11]	自分の人生に対する満足度に対する包括的な認知的判断を評価する	5
SWBS(subjective well-being scale)[1]	SUBI の項目を再検討し開発された主観的幸福感尺度	15

3.5 推定モデルの構築

3.3 節で述べたスマートフォンログに基づく特徴量と, 3.4 節で述べた well-being 調査票回答結果に基づくラベルに基づき, 教師あり機械学習により 1 週間の特徴量に基づき well-being 指標の変動推定モデルを構築する. 前処理として, 特徴量はユーザ単位で平均 0, 分散が 1 となるように標準化 (standardization) を適用し, 標準化後に欠損のあるログは 0 を代入し欠損補完を行う. モデルの構築手法として, 本研究では医学分野で用いられることが多いロジスティック回帰を用いる. モデルの構築においては 3.3 節で述べた 2853 個の特徴量を利用するが, 次元数が多く計算コストが多くなるだけでなく過学習の原因となるため, 構築したロジスティック回帰モデルにおける重みの絶対値の大きいものを抽出することにより特徴量選択を行う.

4. 評価用データセットの収集

以上の提案手法の評価のため, 本研究では 90 名の研究参加者より同意を得た上でスマートフォンのログ, および well-being 調査票回答結果を収集した. 研究参加者の募集は, web 上の募集サイトを通じて, 20 歳以上で性別, 年齢, 職種を問わず行った. スマートフォンログ収集は, 本研究チームが開発した研究用アプリケーションを端末に導入することで自動的に行われた. また, well-being 調査票は 1 週間に 1 度回答を行ってもらった結果を収集した. 以上の方法を約 1 ヶ月継続することにより, 参加者より約 1 ヶ月分のスマートフォンログ, ならびに 5 種類の調査票に対し 5 回ずつの well-being 調査票回答結果を得た. 得られたデータを確認し, 端末のバッテリーセーバー機能などの影響によりログが取得できていない期間や, 調査票への回答がなかった週のデータを除き, 最終的には 330 個の特徴量

表 4 研究参加者 90 名の傾向

年齢	20 歳代 7.5%, 30 歳代 30.1%, 40 歳代 37.6%, 50 歳代 20.4%, 60 歳代 3.2%, 70 歳代 1.1%
性別	男性 38.7%, 女性 61.3%
職種	事務・オフィスワーク 53.8%, 営業 11.8%, 販売・飲食・サービス 8.6%, IT・エンジニア・技術 5.4%, その他 20.4%

表 5 モデル構築に用いる well-being 指標変動のラベル付け結果

調査票	ラベル 0 とラベル 1 の総数
PANAS	178:152
SUBI	191:139
FS	200:130
SWLS	204:126
SWBS	202:128

ベクトルと正解データの組を得た.

以上の手続きにより得られた参加者の情報を表 4 に, 3.4 節の方法により作成した正解データのラベル分布を表 5 にそれぞれ示す. 表 4 より, 幅広い年齢, 性別, 職種の参加者よりデータを収集できたことが確認できる. また, 表 5 より, 2 値分類で用いるラベルに極端な偏りが見られないことが分かる. 以上のデータを用いて, 次章での性能評価を行う.

5. 性能評価

3 章で述べた提案手法について, 4 章で述べたデータセットを用い評価を行う.

5.1 評価手法

4 章で述べた通り, 本研究では 90 名の研究参加者よりデータを収集した. この 90 名に対し, 一人抜き交差検証 (leave-one-subject-out cross validation) を行い, 未知のユーザを想定した評価を行う. 具体的には, 評価対象者を除いた 89 名で構築した推定モデルを用い, 評価対象者 1 名の well-being 指標の変動を推定することを 90 人それぞれに対して行い, 推定結果を得る. 得られた推定結果と正解データを比較することにより, ラベル 1 (well-being が低下する場合) における F 値 (F-measure) を求める. F 値を用いることにより, 実際に well-being が低下したサンプルを検出できたかどうかと, 誤検知を起していないかどうかの両観点で推定モデルを評価する.

5.2 特徴量種別による各種 well-being 指標推定への影響

提案手法によりスマートフォンログより抽出した 3 種類の特徴量の有効性を確認するため, 全ての特徴量を用いて well-being 推定モデルを構築する場合と, 特徴量の種類ごとに well-being 推定モデルを構築した場合における推定精度を比較する. 表 6 に示す通り, 全ての特徴量を用いてモデルを構築する場合において推定精度が最も高い傾向があ

表 6 各種特微量利用時の well-being 指標の変動推定精度 (F 値)

調査票	フィジカル 活動特微量	サイバー 活動特微量	周辺環境 特微量	全特微量 組み合わせ
PANAS	0.732	0.833	0.606	0.907
SUBI	0.751	0.825	0.567	0.821
FS	0.726	0.781	0.552	0.910
SWLS	0.720	0.762	0.504	0.852
SWBS	0.688	0.827	0.545	0.883

り、調査票によっては最大で F 値 0.910 を確認した。SUBI については F 値での評価においてはサイバー活動特微量を利用する場合が最大値であるものの、ラベル 0 の推定も含めた性能 (ROC-AUC) においては、全ての特微量を用いる場合に最高の性能が得られることを確認した。また、それぞれの特微量を用いる場合の傾向としてはサイバー活動特微量が有効であり、次いでフィジカル活動特微量が有効であることを確認した。周辺環境特微量については推定に寄与しづらいことが明らかになった。この結果より、well-being の推定においてスマートフォンログを活用すること、その中でもサイバー空間上での活動に関するログを利用することの有効性を確認した。さらに、well-being の推定においてサイバー空間上の活動のみならずフィジカル空間での身体的な動きも考慮することがより高精度な推定において重要であることが確認でき、利用者の活動を複眼的に捉えられるスマートフォンの利点を確認した。

今回用いた調査票は PANAS のように感情的な側面を測るものや、SWLS のように人生に対する包括的な満足度を測るものなど、well-being をそれぞれの観点で捉えるための調査票であるものの、表 6 で示される結果からは、各種特微量を組み合わせることによりいずれの調査票においても F 値は 0.8 を超えていることから、スマートフォンログを用いることにより安定した精度で well-being を推定可能であることが示された。本評価は一人抜き交差検証で行ったため、評価対象のユーザのスマートフォンの利用特微量はモデル構築には含まれないにも関わらず比較的高い F 値で well-being の変動を推定できることが分かる。この結果より、well-being の指標が変化する場合における人の行動は部分的に共通しており、スマートフォンログを通じて特徴的な行動パターンを捉えることにより、評価対象のユーザが含まれないモデルを用いる場合においても well-being の指標の変動を推定できたものと考えられる。

5.3 推定に寄与した特微量

表 6 の結果より、スマートフォンログを用いて計算した 3 種類の特微量を組み合わせることで利用者の well-being の推定を行えることを確認した。この結果について、実際に推定に寄与した特微量の詳細を分析する。3.5 節で述べた通り、提案手法では計算コスト低減ならびに過学習抑制のため特微量の次元数を削減し、重要な特微量を選択する。

表 7 各 well-being 指標推定における重要特微量選択数の傾向

特微量種別	調査票				
	PANAS	SUBI	FS	SWLS	SWBS
加速度	20	62	21	31	30
角速度	6	16	3	6	7
端末傾き	16	44	21	20	22
歩数	1	4	2	1	1
activity recognition	12	22	9	12	7
位置情報	5	5	5	2	1
バッテリー残量	6	1	2	9	5
充電の開始・終了	0	0	0	0	1
画面の点灯・消灯	3	7	1	5	2
アプリの起動・終了	114	245	117	110	115
イヤホンの着脱	0	2	0	1	0
周辺照度	4	8	4	3	3
気圧	1	7	5	0	4
Wi-Fi 接続状態	4	8	3	1	4
周辺 Wi-Fi 情報	5	3	3	0	0

各調査票に対し最も高い推定性能が得られたフィジカル活動特微量、サイバー活動特微量、および周辺環境特微量の全てを用いる場合について、表 6 に示す性能が得られた推定モデルにおいて採用された特微量の個数について種別ごとに表 7 に示す。表 7 にも示されるように、特微量の次元数は 200 次元程度採用されている推定モデルもあり、個々の特微量の重要度を可視化することが難しいため、本評価では種別ごとに採用された特微量数を示すことにより、本問題設定において効果を発揮した特微量の傾向を俯瞰的に観察する。

この結果より、特微量種別ごとの数値の大小関係などの傾向は全体的に共通しており、アプリの起動・終了に関する特微量が最も採用されていることが分かる。次いで、身体や端末の動きを表す加速度、角速度、端末傾き、activity recognition といったフィジカル活動の特微量が利用されている。一方で、充電の開始・終了、イヤホンの着脱、気圧や周辺 Wi-Fi 情報については一部の調査票の推定において、相対的に重要度が低く推定に用いられなかったことが示されている。こういった傾向はあるものの、提案手法で設計した特微量の各種が推定モデルにおいて採用されており、well-being の変動の推定において各種スマートフォンログを用いることが有用であることを確認した。

アプリの起動・終了の特微量が最も多く採用された理由としては、Google Play Store で定義される 49 種類のカテゴリに加え、オペレーティングシステム (OS) の機能として提供されている 15 種類のカテゴリに、全てのアプリの利用を合わせた 1 つのカテゴリを定めた合計 65 個のカテゴリを定義して特微量化を行うため、特微量の次元数自体が多く、その結果として多くの特微量が採用されたものと考えられる。これらのカテゴリの中でも、特に BUSINESS

カテゴリのアプリの利用の多さに関する特徴量の利用が多く、今回の研究参加者の多くが働いているユーザであったこと、また COVID-19 の影響もあってリモートワークが普及していることから、well-being の変動と BUSINESS アプリの利用が密接に関連していることが示唆されている。また、MAPS AND NAVIGATION, FINANCE, TOOLS, SHOPPING, ENTERTAINMENT といったアプリの特徴量も相対的に多く選出されており、著者らの従来研究 [4] で未活用であったアプリカテゴリを追加することの意義を確認できた。また、加速度や端末の傾きの特徴量が数多く採用されている理由として、ユーザの身体の動き、ならびにスマートフォンを利用する際の姿勢といった身体的な状況を考慮することが可能であり、その結果ユーザの状態理解につながったものと考えられる。これらの特徴量のユーザの精神状態理解における有効性は先行研究 [7] でも確認されており、慣性センサを利用することの意義を確認できた。

6. まとめと今後の課題

本研究では、スマートフォンを用いて利用者の well-being を推定することを目的とし、スマートフォン搭載センサや利用履歴より得られるログデータよりサイバー空間上の活動、フィジカル空間上の活動、および利用者周辺の環境を表現する特徴量を抽出し、well-being の推定モデルの構築および性能評価を行った。多様なユーザを想定した well-being の推定可能性を評価するため、所属や職種を問わない 90 名の参加者より集めた実データに基づき well-being 推定モデルを構築し、評価を通じて各種 well-being の調査票に対して F 値で 0.821 から 0.910 の精度で指標の変化を推定可能であることを確認し、スマートフォンを通じて受動的に得られるログのみを用いる場合においても利用者の well-being の変動を捉えられる見込みを得た。今後の課題として、well-being の指標が下がるかそれ以外かの 2 値分類だけでなく、どの程度下がるかの推定など、より精緻にユーザの well-being の変化を捉える方法を検討したい。

謝辞

本研究は東京大学医学部倫理委員会の承認のもと行われたものである（研究課題名 メンタルヘルスにおける 0 次予防のための基礎研究：スマートフォン・ログによる人の QOL の推定、審査番号 2020318NI）。

参考文献

- [1] 伊藤裕子, 相良順子, 池田政子, 川浦康至: 主観的幸福感尺度の作成と信頼性・妥当性の検討, 心理学研究, Vol. 74, No. 3, pp. 276–281 (2003).
- [2] 濱谷尚志, 落合桂一, 山本直樹, 深澤佑介, 木本勝敏, 上西康平, 太田順, 寺澤悠理, 沖村宰, 前田貴記: 時空間的なスマートフォンログ分析に基づく利用者のストレス推定手法, 情報処理学会論文誌 (IPSI Journal), Vol. 62,

- No. 4, pp. 1113–1127 (2021).
- [3] Amenomori, C., Mizumoto, T., Suwa, H., Arakawa, Y. and Yasumoto, K.: A method for simplified hrqol measurement by smart devices, *International Conference on Wireless Mobile Communication and Healthcare*, Springer, pp. 91–98 (2017).
- [4] 姚文昊, 上西康平, 山本直樹, 濱谷尚志, 山田祐樹, 河田隆弘, 檜山聡, 沖村宰, 寺澤悠理, 前田貴記ほか: メンタルヘルスケアに向けたスマートフォンログデータによる QOL 及び Well-being の推定, 研究報告ユビキタスコンピューティングシステム (UBI), Vol. 2021, No. 14, pp. 1–7 (2021).
- [5] Canzian, L. and Musolesi, M.: Trajectories of depression: unobtrusive monitoring of depressive states by means of smartphone mobility traces analysis, *Proceedings of the 2015 ACM international joint conference on pervasive and ubiquitous computing*, pp. 1293–1304 (2015).
- [6] Guntuku, S. C., Buffone, A., Jaidka, K., Eichstaedt, J. C. and Ungar, L. H.: Understanding and measuring psychological stress using social media, *Proceedings of the International AAAI Conference on Web and Social Media*, Vol. 13, pp. 214–225 (2019).
- [7] Fukazawa, Y., Ito, T., Okimura, T., Yamashita, Y., Maeda, T. and Ota, J.: Predicting anxiety state using smartphone-based passive sensing, *Journal of Biomedical Informatics*, Vol. 93, p. 103151 (2019).
- [8] 佐藤徳, 安田朝子: 日本語版 PANAS の作成, 性格心理学研究, Vol. 9, No. 2, pp. 138–139 (2001).
- [9] 藤南佳代, 園田明人, 大野裕: 主観的健康感尺度 (SUBI) 日本語版の作成と, 信頼性, 妥当性の検討, 健康心理学研究, Vol. 8, No. 2, pp. 12–19 (1995).
- [10] Sumi, K.: Reliability and validity of Japanese versions of the Flourishing Scale and the Scale of Positive and Negative Experience, *Social Indicators Research*, Vol. 118, No. 2, pp. 601–615 (2014).
- [11] 角野善司: 人格 3015 人生に対する満足尺度 (the Satisfaction With Life Scale [SWLS]) 日本版作成の試み, 日本教育心理学会総会発表論文集 第 36 回総会発表論文集, 一般社団法人 日本教育心理学会, p. 192 (1994).