

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

姚文昊¹ 上西康平¹ 山本直樹² 濱谷尚志² 山田祐樹² 河田隆弘² 檜山聡² 沖村宰³
寺澤悠理³ 前田貴記³ 太田順¹

概要：本研究の目的は、日常的に使うスマートフォンログから、QOLとWell-being指標を評価することにより、ユーザの精神状態を把握することである。QOL (Quality of Life) 及び Well-being と、スマートフォンのログデータを記録するフィールド調査を実施した。スマートフォンのログデータから作成した特徴量から、指標の変動や区間を推定するモデルを構築した。14人のデータで、最大で0.82の精度を達成した。加えて、寄与率分析を用いてQOLとWell-beingに影響する要素を考察した。

キーワード：メンタルヘルスケア、スマートフォン、機械学習

1. 序論

メンタルヘルスは、心理学領域のみではなく、世界的にも重視されている。世界精神衛生連盟(WFMH)はメンタルヘルス問題について、正しい知識の普及および意識を高めるため、1992年から毎年10月10日を「世界メンタルヘルスデー」と定めた[1]。しかし、メンタルヘルスの不調による身体、精神の問題は、依然として社会的問題となっている。厚生労働省が平成30年に実施している労働者健康状況調査では、平成30年までの5年間では「仕事や職業生活において強い悩み、不安、ストレスを感じる」労働者の割合は、約6割近くにおよぶ[2]。また、うつ病についても、日本のうつ病への対応は、韓国に次いで先進国の中でも最下位であるとされる[3]。

近年、メンタルヘルスの不調に対する一次予防が重視されている。一次予防とは、病気になる前の健康者に対して、病気の原因と思われるものを発見し、病気の発生を防ぐ等の予防措置をとることにより、健康を増進することである。精神疾患の一次予防を行い、総合的にかつ長期的にメンタルヘルスを測るには、QOL (Quality of Life; 生活の質) および Well-being という2つの指標が重要となる。

QOLは長い歴史を持つ。1947年にWHO (World Health

Organization: 世界保健機関) によって提唱された健康関連QOLの概念/定義は、「単に疾病がないということではなく、身体的にも精神的にも社会的にも完全に満足のいく状態にあること」である。QOLの定義に近いWell-beingは、「健康とは、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・病弱でない事とは意味しない」という1946年のWHO憲章草案によって広く知られるようになった[4]。QOLとWell-beingは同じような目的を持つが、Well-beingは縦断的研究(長期的研究)で使用され、QOLは主に治療において測定するための短期研究でよく使用されている。

QOL・Well-being測定を行う多くの先行研究では、回答者に対して価値観、ムード、対人関係、生活リズムなどについてアンケートを行い、その解答結果からスコアを計算する。しかしながら、日常生活を送っている中で、アンケートに回答させることでデータの収集を行う際の負荷は、必ずしも小さくない。

近年、情報通信技術の飛躍的な発展と、SNS (ソーシャル・ネットワーキング・サービス) やネットショッピング、ゲーム等日常生活を快適にする様々なアプリの存在により、スマートフォンが普及していることは言うまでもない。今やスマートフォンは我々の生活にはなくてはならないものとなっている。特に、大学生のスマートフォンの利用率は極めて高く、株式会社マイナビが就活学生4,656名を対象に実施した調査では、2020年卒学生のスマートフォン保有率は99.4% (前年比0.6pt増) と、ほぼ全員が保有している状況である[5]。

¹ 東京大学
The University of Tokyo

² 株式会社NTTドコモ
NTT DOCOMO, Inc.

³ 慶應義塾大学
Keio University

QOL・Well-being を、スマートフォン利用者の日常活動を測定したデータをもとに推定することができれば、利用者に対する負荷を抑えられる。しかし、これまでそのような研究はごく稀である。スマートフォンが普及した現状を踏まえ、人々が日々使うスマートフォンログから QOL・Well-being の推定ができれば、客観性を持つだけでなく、利便性もあるので非常に望ましいと考えられる。

そこで、本研究の目的は「日常的に使うスマートフォンログから、QOL と Well-being 指標を評価することにより、ユーザの精神状態を把握する」ことである。上記の目的が達成できれば、人々のセルフケアを促し、精神疾患の一次予防および日常の精神健康を見守ることができ、社会的意義は非常に大きいと考えられる。

2. 関連研究

スマートフォンは、加速度センサ、気圧センサ、照度センサ等のセンサを搭載するとともに、GPS（グローバル・ポジショニング・システム）情報とアプリケーションの利用履歴等を記録することができる。そのため、人の日常的なパッシブセンシング（Passive Sensing）手段として重要なもののひとつである。スマートフォンログをもとに、人の不安、ストレス、感情等の日常的な指標を計る関連研究を以下に挙げる。

Fukazawa らは 20 人の被験者に対して、スマートフォンログにより、STAI というアンケートに基づくユーザの不安度の変化を推定した [6]。Yamamoto らはスマートフォンログを用いて、ユーザのストレスを推定した [7]。彼らはアンケートではなく、心拍の間隔 RRI (R-R Interval) から周波数解析してパワースペクトルにしたときの LF (Low Frequency) と HF (High Frequency) を抽出し、それらの比である LF/HF を指標としてストレス推定の正解データとした。Budner らはスマートウォッチとスマートフォンを合わせて、人の感情の推定の研究を行った [8]。彼らは人の感情を愉快 (Pleasant) と活発性 (Active) の 2 軸に分け、9 種類の象限図を作成した。心拍などの生理データ、天気情報、時間情報 (祝日、時間帯)、GPS 情報などが収集され、60 名の被験者に対して計 60 日の測定が行われた。また Bai らはアンケートを用いて、スマートフォンログにより、睡眠の質を推定した [9]。

上記の関連研究では、ストレスや感情のような短期的な精神状態がスマートフォンログから推定されたが、QOL や Well-being のような中長期的な指標に関する議論は行われていない。Amenomori はスマートデバイスを用いて、HRQOL の簡易推定手法を提案した [10]。この研究では、スマートフォンで GPS 情報を収集し、ウェアラブルデバイス E4 wristband で加速度、心拍間隔、皮膚体温などの生体情報を収集した。そして、WHO が提唱した QOL 測定アンケート WHOQOL の結果を正解データとした。この

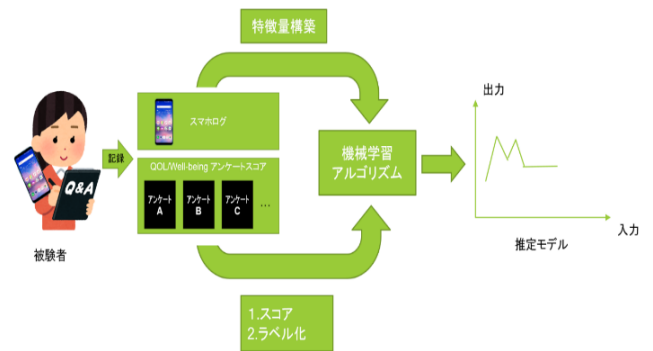


図 1 本研究で提案した推定モデル

研究では、WHOQOL のアンケートの回答結果を正解データとして推定モデルが構築されたが、QOL に関するアンケートは複数存在し、WHOQOL が最もスマートフォンの情報を反映するかどうかは不明である。またウェアラブルデバイスの普及率はスマートフォンの普及率には及ばず、両方の情報を使った推定は利便性を欠く。

上記の関連研究により、従来のスマートフォンログ等による心理状態に関する研究では、多くは短期的な指標を扱っている。QOL を対象とした研究でも、個人差やアンケートの有効性を検証していない。本研究では、より中長期的な QOL・Well-being 指標を複数扱い、スマートフォンログのみから、複数の被験者に対して汎用性のある推定モデルの構築を目指す。

3. 問題設定

本研究で提案したモデルの概要を図 1 に示す。研究参加者は継続的にアンケートに回答する。また、研究参加者のスマートフォンにインストールされた収集アプリが、連続してスマートフォンログを収集する。研究参加者の回答をもとにアンケートスコアの計算を行い、それを元にラベル化を行う。収集したスマートフォンログから、中長期的な QOL・Well-being 指標の推定のため、日と週単位で特徴量を構築する。そして、アンケートのスコアに基づくラベルを出力とし、スマートフォンログから作成した特徴量を入力として、機械学習アルゴリズムを利用した推定モデルを構築する。

4. 提案手法

4.1 回答するアンケート

本研究では、研究参加者に、アンケート PANAS (The Positive and Negative Affect Scales) [11], FS (Flourishing Scale) [12], SUBI (The Subjective Well-being Inventory) [13] の回答を行わせる。これらの 3 つのアンケートでは、一定の特徴 (例えば価値観、心の健康など) を重視し、QOL もしくは Well-being 指標について質問する。表 1 に、各アンケートの特性を示す。

表 1 アンケートの特性

PANAS	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
FS	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
SUBI	感情の主観的状态について、8つの感情状態の存在を質問する：憂うつと不安、敵意、疲れ、活動的快、非活動的快、親和、集中、驚き

本研究では、中長期的に QOL と Well-being を測定するため、研究参加者は、すべてのアンケートに 1 回のみではなく、複数回回答する必要がある。

4.2 特徴量の構築

本節では、QOL と Well-being を推定する特徴量を構築するためのスマートフォンログについて述べる。本研究で収集するスマートフォンログの一覧を表 2 に示す。ログデータは、以下 2 つのパターンに分けられる：実世界活動を反映するログ、バーチャル世界活動を反映するログ、所在環境を反映するログ。

実世界活動を反映するログは、スマートフォン利用者の現実の世界における動作や行動を反映できるログである。例えば、加速度センサログによる人の動き、GPS 情報による人の移動軌跡等、その人が実際にどのような振る舞いがあるかを反映する。実世界活動を反映するログは、主に以下である：加速度、傾き、ジャイロ、行動認識 (Activity Recognition)、位置。

バーチャル世界活動を反映するログは、実世界活動と逆に、ある人が仮想世界、つまりスマートフォンやオンラインにおける操作や履歴を反映するログである。例えば、スマートフォンの画面 ON/OFF によるスマートフォン操作頻度の集計、アプリ履歴によるゲームアプリ利用の回数等、その人がバーチャル世界においてどのような行動をしたかを反映する。バーチャル世界活動を反映するログは、主に以下である：アプリ履歴、画面 ON/OFF、電池容量、充電回数、ストレージ、イヤホンジャックへの接続。

所在環境を反映するログは、ある人が滞在する環境の特性を反映できるログである。例えば、気圧の変化、部屋の明るさ等、その人がいる環境がどのような特徴があるかを記録する。所在環境を反映するログは、主に以下である：照度、気圧、休日であるかどうか。

スマートフォンの収集アプリが正常に起動している間、24 時間ログデータが記録される。上記のログの値の 1 日における平均、最大値、最小値、最大最小差分、分散、回数を計算して特徴量とする。1 日あたりの特徴量は合計 44 個である。毎週の 7 日間の特徴量を並べて、計 308 個の特徴量を得る。

さらに単純に 1 日における特徴量のみならず、1 週間における特徴量を構築する。1 日あたりの 44 個の特徴量に

表 2 スマートフォンログ一覧

名称	取得間隔	出力値
加速度	1 s	x, y, z 軸加速度 (m/s^2)
傾き	1 s	方位角、傾斜角、回転角 (rad)
ジャイロ	1 s	x, y, z 軸を中心とした回転速度 (rad/s)
照度	5 min	明るさ (lx)
気圧	5 min	気圧 (hPa)
加速度 (重力成分除去)	1 s	x, y, z 軸加速度 (m/s^2)
位置情報	5 min	緯度、経度
充電	充電開始/終了時	ON/OFF と充電種別 (USB/AC 電源)
画面 ON/OFF	画面 ON/OFF 時	ON/OFF
アプリ起動履歴	10 min	イベントタイプ番号 (表示/非表示)、パッケージ名、クラス名
イヤホンジャック	装着/脱着時	装着/脱着
電池	5 min	電池残量
Activity recognition	5 min	Google の提供する行動認識 API で取得する情報 (Still, Walk, Vehicle 等)
全体ストレージ容量	1 日 1 回 (23 時)	空容量、総容量 (MB)
休日	1 日 1 回	平日/休日

対して、ダミー変数である「休日であるかどうか」以外の特徴量に対し、7 日間の平均と分散を計算し、計 86 個の特徴量を得る。以上で 1 週間あたり合計 394 個の特徴量ができる。

4.3 推定モデルの構築

本研究では、QOL・Well-being に対する増減推定モデル及び区間推定モデルの 2 つの推定モデルを提案する。フィールド調査中の研究参加者のアンケートの回答内容から、スコアの計算を行う。このアンケートスコアをどのように推定するかで、推定モデルの構成も異なる。前回のスコアに比べ、今回のスコアが増加するか、減少するかを推定するのが増減推定モデルである。スコアが研究参加者個人の平均値よりも上位区間もしくは下位区間に位置するかを推定するのが区間推定モデルである。

4.3.1 推定モデルに基づいた正解データの設定

はじめに増減推定モデルについて説明する。人のメンタルヘルスの変化を QOL・Well-being 指標として把握したい場合に、次のスコアが増加するか減少するかは重要な情報である。スコアの増減推定は、前回のスコアに対しての、スコアの増減を推定する。本研究のフィールド調査では、アンケートは、毎週火曜日に回答される。そのため、




図 2 アンケートスコアの変動の追跡




図 3 ユーザごとの区間推定モデルの設定

該当週の火曜日のスコアと前の週の火曜日のスコアとの差を考える。図 2 にその差を示す。

この手法では、ユーザの QOL 及び Well-being 指標が上がったもしくは変動しなかった場合、および下がった場合の 2 分類をする。具体的には、該当週のアンケートのスコアが前回のスコアより上がったもしくは変動しなかった場合はラベル 1、スコアが下がった場合はラベル 0 をつける。これにより、変動推定問題が 2 分類問題に帰着する。第 i 週の時に、ground truth のラベル $y_{trace-i}$ を以下に従って付ける：

$$y_{trace-i} = \begin{cases} 1 & ; score_i \geq score_{i-1} \\ 0 & ; score_i < score_{i-1} \end{cases} \quad (1)$$

続いて、区間推定モデルについて説明する。人のメンタルヘルスについて、一定な範囲の中であれば、小さな変化があっても問題ないと考えられる。したがって、人のメンタルヘルスが正常の範囲にあるか、それとも正常ではない範囲に陥るかを判断するため、QOL・Well-being 指標の具体的なスコアではなく、スコアがどの区間にあるかが重要となる。

ユーザの精神状態がどの区間にあるかを推定するために、以下の手法を提案する。あるユーザに対してアンケートのスコア区間が $[a, c]$ であるときを考える。しきい値を a と c の平均値 b とし、区間 $[a, b]$ は L-QOL (Low QOL Level) とし、 $[b, c]$ は H-QOL (High QOL Level) とする。図示すると、図 3 のようになる。

H-QOL 区間におけるスコアにラベル 1 を、L-QOL 区間

におけるスコアにラベル 0 をつける。これにより、増減推定問題と同じように、区間推定問題も 2 分類問題に帰着できる。第 i 週のラベル $y_{range-i}$ を以下に従ってつける。

$$y_{range-i} = \begin{cases} 1 & ; score \geq average(a, c) \\ 0 & ; score < average(a, c) \end{cases} \quad (2)$$

4.3.2 学習アルゴリズム

本研究の増減推定モデル及び区間推定モデルでは、Random Forest [14] を用いて構築する。Random Forest は複数の決定木を組み合わせたアンサンブル学習モデルである。他の学習アルゴリズムと比べ、Random Forest のメリットがいくつか存在する。まずは複数の木構造であり、変数が多い問題の処理に対して有利である。本研究では、特徴量が最大 394 個であり、この恩恵を受けられる。また、どの変数が分類結果に対して重要であるかを計算できる。本研究では、どのスマートフォンログの特徴量が QOL・Well-being 指標の推定に役に立つかを分析したい。以上の理由から、本研究では Random Forest を利用する。構築した推定モデルの評価のため、学習データとテストデータを 4 : 1 で割り当てる、 k -分割交差検証 ($k = 5$) を行った。

また、被験者のスマートフォンの利用パターンは複数存在する。そのため、本研究ではスマートフォンの利用パターンに基づいて、クラスタリングをしてクラスタごとにモデルを構築する。 k -means 法 [15] を用いて、クラスタリングを行う。 k -means 法は教師なし学習において有効な手法である。

4.4 フィールド調査の手順

研究参加者は 20 代の大学生 14 人で、そのうち 12 人が男性、2 人が女性である。期間は 9 月 29 日から 12 月 8 日までの合計 10 週間である。実施にあたっては東京大学倫理委員会の承認を受けた。

研究参加者は、著者らが開発したスマートフォンログ収集アプリを自分のスマートフォンにインストールした。期間中、スマートフォンログが 24 時間記録される。研究参加者は、毎週火曜日に PANAS, FS, SUBI の回答を行う。これらのアンケートはウェブ上のフォームで配布し、研究参加者各自がオンラインで回答する。

5. 結果と考察

5.1 クラスタリングの結果

本研究では、14 名の研究参加者に対して合計 10 週間のフィールド調査を行い、各アンケートあたり 140 個のデータを取得した。スマートフォンログから抽出した 394 個の特徴量を用いて研究参加者のクラスタリングをした結果を表 3 に示す。3 つのクラスタの特性を考察するため、実世界活動とバーチャル世界における活動におけるいくつかの代表的な特徴量、例えばバーチャル世界における各アプリ

表 3 クラスごとの特性

クラス	人数	特徴量のまとめ	クラス特性
1	9	加速度平均が高い, SNS アプリ, メッセージアプリ, ゲームアプリ, ショッピングアプリ利用が多い	バーチャル世界活動が多い
2	2	ジャイロ平均が高い	
3	3	総移動距離が長い, 家からの最大移動距離が長い, Foot, bicycle 集計が多い, 画面 ON/OFF 回数が多い	実世界活動が多い

の利用, 実世界活動を反映する加速度, 移動距離について, 各クラスにおける平均値を計算し, 表 3 に併記した.

クラス 1 ではアプリの利用が多いため, クラス 1 の参加者はバーチャル世界における活動が多い傾向がある. また, クラス 1 では加速度平均も大きい, スマートフォンを操作する際にスマートフォンの動きにより加速度も生じるため, ここでは加速度平均もバーチャル世界における活動との相関があると考えられる. クラス 3 では移動距離, 歩き, 自転車利用等に特徴があり, 実世界における活動が多い傾向がある. また, クラス 3 では, 画面 ON/OFF 回数も多いが, スマートフォンの動きにより画面が起動するケースもあるため, ここでは画面 ON/OFF 回数も実世界における動きと関係がありうると考えられる. クラス 2 については特性が少なくかつ欠損値が多いので, ここでは議論しない.

5.2 学習モデルの結果

研究参加者全体及びクラスごとの学習結果について示す. 増減推定モデルの精度および F 値を図 4 と図 5, 区間推定モデルの精度および F 値を図 6 と図 7 に示す.

3 つのアンケートの研究参加者全体に対する推定モデルおよびクラス 1 に対する推定モデルの推定精度と F 値はすべて 0.7 を超えた. また, 増減推定モデルと区間推定モデルどちらでも, クラス 1 の学習結果 (学習精度, F 値) は, 研究参加者全体を対象に構築した推定モデルの結果より良くなっている. 増減推定モデルの FS のように, 精度が 0.8 を超えるものもある. これはクラスリングにより, 同じ利用パターンの研究参加者に対応した推定モデルを作成できたことによると考えられる.

クラス 3 は研究参加者全体を対象に構築した推定モデルより学習精度が下がった. PANAS と FS では 0.6 以上の精度が得られたが, SUBI ではこれを下回った. 同じ利用パターンのユーザは集められたが, クラスあたりの人数は 3 名であり学習データが少なかった.

クラス 2 の学習精度が最も低かった. その原因は学習データが少なく, かつ中の欠損値が多かったことによるも

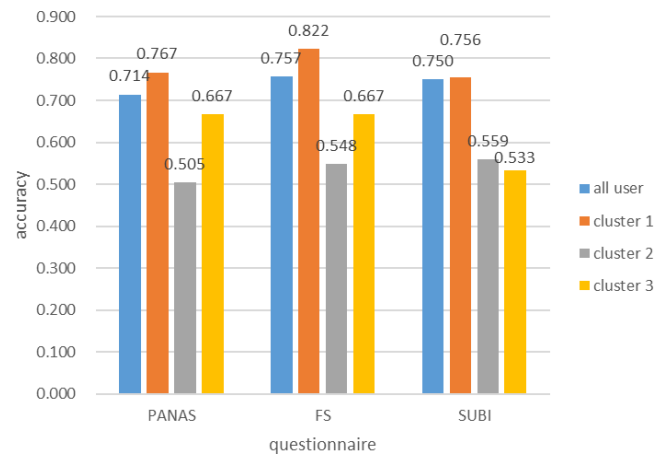


図 4 精度の比較 (増減推定モデル)




図 5 F 値の比較 (増減推定モデル)

のと考えられる.

5.3 上位特徴量の考察

本節では, 各アンケートに対する増減推定モデルと区間推定モデルの上位特徴量について議論する. ここでは, 各モデルの上位 10 位の特徴量を算出する. PANAS の結果を表 4, FS の結果を表 5, SUBI の結果を表 6 に示す.

PANAS の上位特徴量では, 実世界活動に関する特徴量が多い表 4. 特に増減推定モデルの上位 5 位と区間推定モデルの上位 3 位は, すべて実世界活動に関する特徴量である. PANAS は主に短期的なムード, 例えば喜び, ゆうつ, 悲しさ等の感情を問うアンケートである. したがって, 人の実世界における主観的な活動, 例えば動き, 歩き等は主に PANAS で見るような短期的なムードを反映すると思われる. それ以外に, 増減・区間推定モデルのどちらでも傾き平均 (y 方向) が上位特徴量とされている. スマートフォンを使用する際 (座っているとき, 立っているとき), もしくはスマートフォンをテーブルの上から取って画面を見るときに, 手首のスナップで変化するのは, y 軸方向の傾きであって, x 軸や z 軸方向の傾きは大きく変化しない. スマートフォンの地面からの傾きを知ることで,

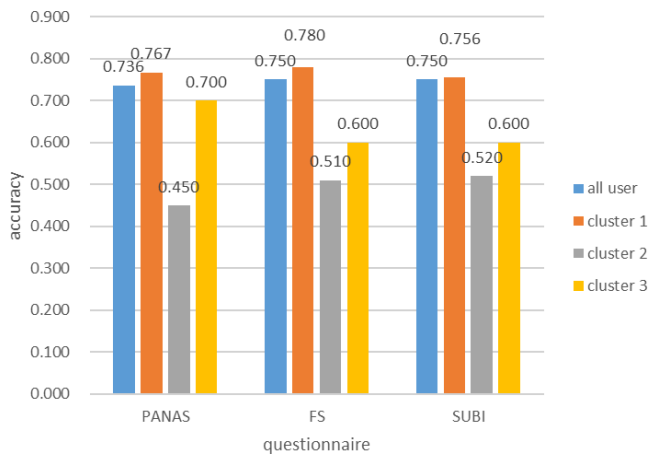


図 6 精度の比較 (区間推定モデル)




図 7 F 値の比較 (区間推定モデル)

スマートフォンを使用しているときの姿勢を推定することができ、ユーザの短期的なムード、例えば喜んでリラックスしているのか、緊張しているのかといったその人の精神状態と関係のある情報を得られていると考えられる。

バーチャル世界における活動に関して、増減推定モデルではメッセージアプリとゲームアプリの1週間平均が出てくる。ユーザがスマートフォンを用いて誰かと連絡し、もしくはゲームをする際に、気分転換ができると考えられる。区間推定モデルでは画面 ON/OFF 回数の1週間平均が出てくる。ユーザの段階的な気分がスマートフォンの操作回数(スマートフォンを見る等)に影響する可能性がある。例えばある人が数日間イライラして、画面を繰り返してみれば、画面 ON/OFF 回数の値に影響がある。

FS の増減推定モデルと区間推定モデルの上位特徴量を比較すると、増減推定モデルでは上位特徴量に気圧、照度のような環境に関する特徴量が多く、区間推定モデルではバーチャル世界における特徴量と実世界活動を反映する特徴量が半々であり、人の主体的な活動を反映する特徴量が多い。そのため、環境(気圧、照度など)が人の価値観の変動に影響がある一方で、価値観がどのような区間にあるか(精神状態が良いのか、悪いのか)に関しては、人の

表 4 PANAS の上位特徴量

順番	特徴量 (増減推定モデル)	特徴量 (区間推定モデル)
1	加速度平均	傾き分散 (y 方向)
2	ジャイロ最大最小差分	傾き平均 (y 方向)
3	ジャイロ分散	家から最大移動距離
4	傾き平均 (y 方向)	イヤホン接続回数
5	still 集計回数	照度分散
6	メッセージアプリ集計	ジャイロ分散
7	ゲームアプリ集計	画面 ON/OFF 回数
8	充電回数	家から最大移動距離
9	充電回数	気圧平均
10	日曜日	傾き平均 (y 方向)

表 5 FS の上位特徴量

順番	特徴量 (増減推定モデル)	特徴量 (区間推定モデル)
1	照度平均	Bicycle 集計回数
2	Foot 集計	加速度平均
3	傾き平均 (y 方向)	電池容量
4	気圧平均	メッセージアプリ集計
5	気圧平均	イヤホン接続回数
6	加速度分散	ショッピングアプリ集計
7	Foot 集計	ゲームアプリ集計
8	傾き平均 (y 方向)	Vehicle 集計回数
9	画面 ON/OFF 回数	傾き分散 (y 方向)
10	加速度最大最小差分	ジャイロ分散

表 6 SUBI の上位特徴量

順番	特徴量 (増減推定モデル)	特徴量 (区間推定モデル)
1	気圧平均	照度分散
2	加速度平均	照度最大最小差分
3	気圧最大値	気圧最小値
4	電池容量	気圧分散
5	加速度分散	Still 集計
6	ジャイロ平均	ジャイロ最小値
7	SNS アプリ集計	充電回数
8	照度最大値	傾き平均 (y 方向)
9	加速度分散	画面 ON/OFF 回数
10	加速度分散	傾き分散 (y 方向)

活動に関する特徴量と相関のある特徴量の方がうまく推定できる可能性がある。

SUBI は主に人生に対する満足感、達成感、近親者の支え、社会的な支え、家族との関係について質問をする。また、外的(他人との相互作用)要因に対する質問数は、すべてのアンケートの中で最も多い。そのため、解析前には、上位特徴量にはメッセージアプリや SNS アプリの利用など対人関係と相関のある特徴量が頻繁に出ると予想された。しかし、実際の結果では、対人関係のある特徴量は増減推定モデルの1つしか出ておらず(SNS アプリ集計)、区間推定モデルでは全く出ていない表 6。したがって、人の対人関係に関する状況、例えば家族との一体感、友達との関係、職場での人間関係は実世界におけるコミュニケーショ

ンの割合がより多く、メッセージアプリや SNS アプリに反映されづらかったものと考えられる。SUBI の上位特徴量では環境に関する特徴量が多い (増減推定モデルの 1 位と 3 位, 区間推定モデルの 1~4 位)。その特性は FS の増減推定モデルと同じである。SUBI は対人関係以外に, 長期的な価値観, 例えば人生の面白さ, 生活水準・社会地位, 生活の幸せに関する質問をする。その部分の内容では, FS と SUBI は同様である。

6. おわりに

本研究では, スマートフォンのログを用いて, QOL・Well-being を指標として中長期的なメンタルヘルスを推定することを目的とした。フィールド調査を行い, 研究参加者のスマートフォンログを記録した。また, QOL・Well-being のアンケートに定期的に回答させた。

スマートフォンログに基づき, 研究参加者のクラスターリングを行った。研究参加者は 3 つにクラスターリングされた。その中で, バーチャル世界における活動の多い傾向のある研究参加者のクラスターと, 実世界における活動の多い傾向のある研究参加者のクラスターができた。その後, 研究参加者全体, およびクラスターごとにアンケートスコアの増減推定モデルおよび区間推定モデルを構築した。研究参加者全体に対して, 0.7 を超える精度で推定ができた。また, バーチャル世界における活動の多い傾向のある研究参加者のクラスターの推定精度は, 研究参加者全体から構築した推定モデルの精度より高く, 特に FS では 0.822 に至った。最後に, 3 つのアンケートに対して推定モデルの上位特徴量を考察した。

今回の上位特徴量分析では, どの特徴量の寄与率が高いかについて考察した。しかし, その特徴量の値の変動と QOL・Well-being との関係 (例えばある特徴量の値が上がると, 全体の QOL・Well-being 指標が上がるかもししくは下がるか) については議論していない。今後ではこのような分析も加えて, 研究参加者の QOL・Well-being 指標を改善するための行動変容に役に立てると考えられる。

参考文献

- [1] 厚生労働省: 世界メンタルヘルスデー JAPAN2020 特設サイト: 世界メンタルヘルスデーについて, (オンライン), 入手先 (<http://www.jmar-llg.jp/world-mental-health-day-japan2020/about.html>) (参照 2020-12-08).
- [2] 日本医療・健康情報研究所: 職場のメンタルヘルス対策 日本のうつ病への対応は最下位, (オンライン), 入手先 (<http://tokuteikenshin-hokensidou.jp/news/2015/004159.php>) (参照 2020-12-08).
- [3] 厚生労働省: 平成 30 年労働安全衛生調査 (実態調査), (オンライン), 入手先 (<https://www.mhlw.go.jp/toukei/list/h30-46-50b.html>) (参照 2020-12-08).
- [4] WHO: World Health Statistics 2010, (online), available from (<https://www.who.int/whosis/whostat/2010/en/>) (accessed 2021-01-19).

- [5] 株式会社マイナビ: 2020 年卒マイナビ大学生のライフスタイル調査, (オンライン), 入手先 (<https://saponet.mynavi.jp/release/student/life/mynavilifestyle2020/>) (参照 2021-01-20).
- [6] 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).
- [7] Yamamoto, N., Ochiai, K., Inagaki, A., Fukazawa, Y., Kimoto, M., Kiri, K., Kaminishi, K., Ota, J., Okimura, T., Terasawa, Y. et al.: Physiological stress level estimation based on smartphone logs, *2018 Eleventh International Conference on Mobile Computing and Ubiquitous Network (ICMU)*, IEEE, pp. 1-6 (2018).
- [8] Budner, P., Eirich, J. and Gloor, P. A.: "Making you happy makes me happy"-Measuring Individual Mood with Smartwatches, *arXiv preprint arXiv:1711.06134* (2017).
- [9] Bai, Y., Xu, B., Ma, Y., Sun, G. and Zhao, Y.: Will you have a good sleep tonight?: sleep quality prediction with mobile phone., *BODYNETS*, Citeseer, pp. 124-130 (2012).
- [10] 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).
- [11] 川人潤子, 大塚泰正, 甲斐田幸佐: 日本語版 The Positive and Negative Affect Schedule (PANAS) 20 項目の信頼性と妥当性の検討, *広島大学心理学研究*, No. 11, pp. 225-240 (2011).
- [12] 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).
- [13] 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).
- [14] Breiman, L.: Random forests, *Machine learning*, Vol. 45, No. 1, pp. 5-32 (2001).
- [15] MacQueen, J. et al.: Some methods for classification and analysis of multivariate observations, *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, Vol. 1, No. 14, Oakland, CA, USA, pp. 281-297 (1967).