

# 生活リズムの類似性や周期性に基づく 心身の健康状態の推定と予測

高橋 雄太<sup>1,a)</sup> 荒川 豊<sup>1,2</sup> 安本 慶一<sup>1</sup>

概要：人の心身の健康状態を推定・予測することはヘルスケアにおいて重要であり、様々な応用先に利用できる。これまで、ストレスの推定に関する幾つかの研究が行われてきたが、健康、特にフィジカルな健康状態に着目した研究は少ない。健康状態は数日間の生活の積み重ねが影響すると考えられるが、多くの既存研究は、健康の推定や予測に直近の1日のみのデータを使っていることが多い。しかし、予測精度の向上には数日間のデータにおける生活リズムや周期性を分析することが重要であると考えられる。さらに、既存研究では、様々な生理的なデータを取得可能な高価なウェアラブルセンサが使用していることが多いが、より普及性の高い簡易活動量計を用いた健康状態の推定・予測は行われていない。本研究ではリストバンド型の簡易活動量計から収集した数日間のライフログを用いて複数日にまたがって現れる生活リズムや周期性のパターンを抽出し、機械学習によって、心身の健康状態の推定・予測を試みた。複数の機械学習アルゴリズムを使って、悪い・普通・良いの3段階のフィジカルヘルスとメンタルヘルスを推定（使用するライフログデータの最後の日の状態を推定）・予測（最後の日の翌日の状態を予測）したところ、個人ごとに構築した分類モデルにおいて、フィジカルヘルスに関しては推定80%、予測74%のF値、メンタルヘルスに関しては推定83%、87%のF値を実現できた。さらに、複数日にわたる生活リズムや活動の周期性が推定・予測精度の向上に大きく寄与していることが分かった。

キーワード：健康，生活リズム，機械学習，ライフログ，ウェアラブルデバイス

YUTA TAKAHASHI<sup>1,a)</sup> YUTAKA ARAKAWA<sup>1,2</sup> KEIICHI YASUMOTO<sup>1</sup>

## 1. はじめに

人々の心身の健康を把握することはヘルスケアにおいて重要であり、予防、QoL (Quality of Life) の向上、健康増進などに役立てることができる。特に、ITを用いたヘルスケア技術に注目が集まっており、健康の情報を元にした患者のリモートモニタリングや運動プログラムの推薦、自発的な健康づくり、労働生産性の向上などへの応用が期待されている。そして、次の日の健康状態が予測可能であれば、より高度なヘルスケアプログラムを提供することができる。

健康状態は、日々の生活リズムと深く関係している。規

則的な睡眠や食生活や適度な身体活動は生活習慣病の予防とともにフィジカルヘルス、メンタルヘルスの両方に良い効果をもたらす。ウェアラブル技術やIoT (Internet of Things) の発展により、省電力で心拍のような生体データを常時記録することができるようになった。これにより、活動や睡眠を検知し、人の生活リズムをライフログとして安価に収集できるようになってきた。このヘルスに関するライフログは、健康状態の把握・予測に活用できる潜在力を秘めている。

健康状態のような内的な状態は直接計測できないため、行動のような外的な状態に比べて計測・推定が困難であるが、その必要性から、内的状態を推定・予測する研究は近年増加の傾向にある。これまでスマートフォンやウェアラブルセンサを用いて、ストレス [1], [2], [3], [4], 感情 [5], メンタルヘルス [1], [2], [4], アカデミックパフォーマンス [1], [2], 幸福度 [1], [4], [6] などの推定や予測が行われている。特にストレスに関しては多くの研究があり、PC操

<sup>1</sup> 奈良先端科学技術大学院大学  
Nara Institute of Science and Technology, 8916-5, Takayama-cho, Ikoma, Nara 630-0192, Japan

<sup>2</sup> JST さきがけ  
JST PRESTO, 4-1-8 Honmachi, Kawaguchi, Saitama 332-0012, Japan

<sup>a)</sup> takahashi.yuta.to2@is.naist.jp

作 [7], [8], 音声 [9] などから推定する研究もある。しかしながら健康状態に関しては研究事例が多くない。特に身体的な健康状態を扱っている研究はない。また、推定・予測に用いるデータが直近の1日のみであることが多い。健康状態は日々の生活規則が大きく関係することが予測される。例えば、数日間睡眠時間が少なく、睡眠習慣が不規則であれば健康状態が悪化しやすいと考えられる。そこで、本研究では、数日間の生活リズムの特徴量と日ごとの特徴量を比較した類似性や周期性に関する特徴量も推定・予測に取り入れる。このような工夫を取り入れつつ、健康状態を構成する大きな要素であるフィジカルヘルスとメンタルヘルスの推定・予測に取り組む。ここで推定はライフログの最後の日の健康状態を推定することであり、予測はライフログの最後の日の次の日の健康状態を予測することである。

健康状態を推定・予測するにあたり、まず、ウェアラブルデバイスを用いてライフログを収集する。ウェアラブルデバイスは市販の歩数・心拍・睡眠のライフログが収集可能なデバイスを使用する。そして、毎日フィジカルヘルスとメンタルヘルスに関するアンケートを実施し、正解値を収集する。被験者のアンケートの負担をできる限り減らすため、専用のスマホ用アンケートアプリを開発し、使用する。そして、ライフログから生活リズムに関する特徴量と、相関分析を元に生活リズムの類似性と周期性に関する特徴量を抽出し、機械学習によって健康状態の推定・予測を行なう。

## 2. 関連研究

近年では、内的状態を推定・予測する研究が増えつつある。このような研究では、ストレス [1], [2], [3], [4], 感情 [5], メンタルヘルス [1], [2], [4], アカデミックパフォーマンス [1], [2], 幸福度 [1], [4], [6] などが対象とされ、人の内的状態とスマートフォンやウェアラブルセンサから得られるデータとの関連性が少しずつ明らかになっている。

Sano ら [1] は、スマートフォンとウェアラブルセンサを用いて、アカデミックパフォーマンスと睡眠の質とストレスレベルとメンタルヘルスの推定を行っている。スマートフォンからは SMS, Email, 電話の着信, スクリーンの状態などを収集し、ウェアラブルセンサからは加速度, 皮膚電位, 温度などのデータを収集している。そして、朝と夜にアンケートを行い、睡眠や幸福度など様々な項目の情報を収集し、これも推定に利用している。正解値となる指標として、アカデミックパフォーマンスには、授業の成績の平均を表す Grade Point Average (GPA), 睡眠の質は Pittsburgh Sleep Quality Index (PSQI), ストレスは、perceived stress scale (PSS), SF-12 Physical and Mental Health Composite Scale (MCS) を用いている。実験では、66 人の実験協力者から 30 日分のデータをしている。4 つの指標の推定では、上位 20%と下位 20%の二つのグループ

を作成し、これらの 2 値分類を行っている。全体の結果としては、67-92%の精度が得られ、スマートフォンよりウェアラブルセンサの方が推定精度が高いことを報告している。

Wang ら [2] は、スマートフォンから得られるデータを用いてメンタルヘルス、アカデミックパフォーマンス、行動の傾向の評価を行っている。スマートフォンの加速度、マイクロフォン、照度センサ、GPS からアクティビティ、会話、睡眠、位置を測定・推定し、収集している。そして、1日に数回、通知を行い、ストレスに関する質問、16枚の写真から写真を選択してもらい、その時の感情を抽出する Pick-A-Mood (PAM) によりデータの収集を行っている。メンタルヘルスは鬱、活発度、ストレス、孤独の4つの軸で評価している。それぞれの評価方法として、鬱は patient health questionnaire (PHQ-9), 活発度は flourishing scale, ストレスは PSS, 孤独は UCLA loneliness scale を用いている。アカデミックパフォーマンスは GPA で評価している。実験は、スマートフォンのプログラミングの授業に参加する生徒 75 名に対して 10 週間行われた。相関分析の結果、鬱は発話や睡眠、ストレスは発話、孤独は活動量、アカデミックパフォーマンスは室内の移動量や発話に関して相関を持つことが報告されている。活発度に関しては有意確率  $p < 0.05$  を満たすような相関は得られていない。

Taylor ら [4] は、ウェアラブルセンサ、スマートフォン、天気を用いて、次の日の感情、ストレス、健康の予測を行っている。ウェアラブルセンサは Affectiva 社の Q sensor を使用しており、皮膚電位、加速度、温度を 8Hz で収集し、スマートフォンからは電話、SMS、スクリーンの状態、位置情報を収集している。正解値として、感情 (sad/happy), ストレス (stressed out/calm), 健康 (sick/healthy) を朝と夜に毎日収集している。実験協力者は、それぞれに対し主観的に 100 点満点でスコアをつける。実験は 104 名に対して 30 日間行われた。Taylor らの手法の特徴として、マルチタスク学習を使用していることがあげられる。この研究では、感情、ストレス、健康の3つの予測タスク行っている。予測結果として、性別や Big Five trait taxonomy を元に似通ったパーソナリティを持つ人をクラスタリングし、クラスタで分けて学習させた結果が最もよく、それぞれ 70-80%の精度で予測することができている。予測モデルとしては、Multi-Task Learning を学習させたニューラルネットワーク、Multi-Task Multi-Kernel Learning で学習させたニューラルネットワーク、Hierarchical Bayesian Logistic Regression を使用している。

本研究では、専用のデバイスではなく既製品の簡易活動量計を用いているため、実用性が高く、導入コストが低い。そして、これまで対象とされていなかったフィジカルヘルスの推定・予測を試みている。また、推定・予測には、1日ではなく数日分のデータを使用している。

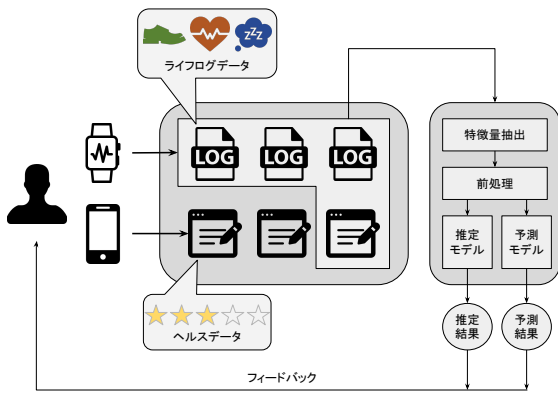


図 1 心身の健康状態の推定と予測の流れ

Fig. 1 The work flow of prediction/estimation physical and mental health.



図 2 リストバンド型ウェアラブルデバイス

Fig. 2 Wrist-worn wearable device.

### 3. 心身の健康状態の推定と予測

本研究では、心身の健康状態をライフログデータから推定・予測する。図 1 に手法の流れを示す。まず、リストバンド型ウェアラブルデバイスからは歩数、心拍、睡眠のライフログデータを収集し、スマートフォンからは心身の健康状態に関するヘルスデータ（アンケート結果）を収集する。そして、それぞれのデータから推定・予測のための個人の推定・予測モデルを構築しておき、1日分のライフログが収集されたら健康状態を推定・予測する。推定・予測結果はユーザや他のアプリケーションへフィードバックすることで活用できる。

#### 3.1 ウェアラブルデバイス

本研究では、実用性を高めるため、導入コストが低く、ユーザビリティの高い、市販のリストバンド型ウェアラブルデバイスを用いることにした。市販のウェアラブルデバイスにも様々な種類があるが、健康と睡眠は大きく関連していることから心拍センサが実装されている SONY 社の

表 1 健康状態に関する質問項目

Table 1 Question items about a health condition.

質問内容	評価方法
(a) 本日の身体の調子はよかった	5 段階
(b) 本日のメンタルの調子はよかった	5 段階

SmartBand2<sup>\*1</sup> を使用することにした。

SmartBand2 は、ライフログを目的とした簡易活動量計で、心拍数、ストレスレベル、消費カロリーや歩数の情報をユーザに提示する。図 2 に SmartBand2 を装着した様子を示す。本デバイスは、Android, iOS 両方のスマートフォンに対応しており、Android であれば Google Fit<sup>\*2</sup>、iOS であれば HealthKit<sup>\*3</sup> にライフログは蓄積され、取り出すことができる。特徴としては、睡眠の認識が可能なこと、2日程度電池が持つこと、充電端子が独自の規格でないこと、防水防塵であることがあげられる。加速度センサと光学式の心拍センサが内蔵されているため、歩数の検知や心拍の測定、睡眠の認識が可能である。なお、心拍は10分間おきに計測される。

#### 3.2 ヘルスデータ

健康状態の定量的な評価というのは難しく、現時点では自己の状態を自覚し主観的に評価するしかない。しかしながら、医者が患者と対話することで病を特定するように、主観的な健康の評価は重要である。アメリカの18万人規模の調査 [10] では、ストレスが健康に影響を与えると認識している人の方が、ストレスが健康に影響がないと認識している人と比べて、健康やメンタルヘルスの状態が悪く、ストレスが実際に健康に大きく影響したときの早期死亡のリスクが43%も高いことが報告されている。このように、健康の認知が自身の健康に影響を及ぼすほど主観的な健康状態というのはセンシティブであるが、逆にいえば、主観的な健康状態というのは信頼性が高いといえる。

本研究では、被験者のアンケートの回答の負荷を考慮し、表 1 のようなシンプルな質問項目で主観的な心身の健康状態のデータを収集する。(a) の項目がフィジカルヘルス、(b) の項目がメンタルヘルスに対応する。どちらも5段階の Likert Scale で回答してもらい、1が「全く同意できない」、2が「同意できない」、3が「どちらともいえない」、4が「同意できる」、5が「非常に同意できる」とする。また、図 3 に示すアンケート用のスマートフォンアプリケーションを開発した。個人所有のスマートフォンにアプリケーションをインストールすることを想定し、クロスブ

\*1 SmartBand 2 (スマートバンド 2) SWR12 — スマートプロダクト — ソニーモバイル公式サイト: <http://www.sonymobile.co.jp/product/smartproducts/swr12/>

\*2 Fit Google: <https://www.google.com/intl/en/fit/>

\*3 HealthKit - Apple Developer: <https://developer.apple.com/healthkit/>



図 3 ヘルスデータ収集のためのスマートフォンアプリケーション  
Fig. 3 Smartphone application to collect health data.

ラットフォームに対応した Xamarin<sup>\*4</sup>で開発し、Android と iOS 両方の OS に対応可能である。

### 3.3 特徴量の抽出

収集するライフログは心拍  $x_t^h$ 、歩数  $x_t^w$ 、睡眠  $x_t^s$  の 3 種類である。心拍は 1 秒間当たりの脈拍数、歩数は 1 分間あたりの歩数で量的な値であり、睡眠は寝ている ( $x_s = 1$ ) か、起きている ( $x_s = 0$ ) かの質的な値となる。特徴量としては、1 日のライフログから算出する生活特徴と 2 日間のライフログから算出する生活規則特徴の 2 種類を抽出する。

生活特徴は、1 日のライフログから得られる特徴量で、1 日全体のセグメントデータから算出する特徴量  $F_1(\mathbf{x})$  と時間窓によって分割した各セグメントから算出する特徴量  $F_2(h, \mathbf{x})$ ;  $h \in \{1, 2, 3, 4, 6, 12\}$  の 2 種類がある。ここで  $d$  は特定の日時、 $h$  は時間窓の幅で 24 の約数である。そして、それぞれのセグメントから表 2 に示す特徴量を抽出する。 $F_1$  に関しては 16 種類で固定となるが、 $F_2$  に関しては指定する時間幅によって異なり、例えば、 $h = 4$  であれば  $24/4 \times 16 = 96$  種類となる。

生活規則特徴は 2 日間のライフログから算出する特徴量であり、相関分析によって 2 日間のライフログの類似度  $F_3(\mathbf{x}_d, \mathbf{x}_{d-1})$  と周期の特徴  $F_4(\mathbf{x}_d, \mathbf{x}_{d-1})$  を算出する。類似度は生活リズムが同じパターンであるかを表しており、周期は生活リズムが 24 時間周期からズレているかを表す。どちらも生活の規則性に関する特徴量である。事前準備として、各データを 1 時間間隔に分割し、各セグメントの値として、歩数、心拍であれば中央値、睡眠であれば睡眠時

表 2 生活特徴の種類

Table 2 Types of life features.

種類	特徴量
心拍	平均
	標準偏差
	最小
	最大
	第一四分位数
	中央値
	第三四分位数
歩数	合計
	平均
	標準偏差
	最小
	最大
	第一四分位数
	第三四分位数
睡眠	合計
計	16 種類

間 [分] を算出しておき、セグメントの平均値を引くことで平均値が 0 になるよう調整する。この調整は周期の特徴の算出において必要となる。

類似度としては相関係数を用いる。相関係数  $F_3$  は以下の式により算出する。

$$F_3(\mathbf{x}_d, \mathbf{x}_{d-1}) = \frac{\sum_{t=1}^n (\mathbf{x}_d(t) - \bar{\mathbf{x}}_d)(\mathbf{x}_{d-1}(t) - \bar{\mathbf{x}}_{d-1})}{\sqrt{\sum_{t=1}^n (\mathbf{x}_d(t) - \bar{\mathbf{x}}_d)^2} \sqrt{\sum_{t=1}^n (\mathbf{x}_{d-1}(t) - \bar{\mathbf{x}}_{d-1})^2}} \quad (1)$$

相関係数が 1 に近いほど比較した 2 日間は似た生活リズムであることを意味する。

周期の特徴として、自己相関関数を用いて 2 日分の時系列データから周期を算出する。2 日間の生活が規則正しければ 24 時間の周期が得られる。自己相関は時系列データ自身を畳み込みさせ、相関を算出していく手法で、おおよその時系列データの周期を求めることができる。データ数が  $N$  であり、 $\mathbf{x}_{d-1}$  と  $\mathbf{x}_d$  を結合した離散系列データ  $\mathbf{x}(i)$  の自己相関関数は

$$R_{xx}(i) = \frac{1}{N/2} \sum_{j=0}^{N/2} x(i-j)x(j) \quad (2)$$

で表される。12 時間以内の周期は無視したいため、 $i > 12$  における  $R_{xx}(i)$  の極大を求める。値が最も大きな極大値の位置  $k = \arg \max_{i > 12} R_{xx}(i)$  が求めたい生活周期であり、この  $k$  を特徴量  $F_4$  とする。なお、極大が見つからない場合は  $k = 0$  とした。

### 3.4 推定・予測手法

収集した体調アンケートとライフログを用いて、一日の体調の推定と次の日の体調の予測を行う。アンケートは、

<sup>\*4</sup> Mobile App Development & App Creation Software - Xamarin : <https://www.xamarin.com/>

毎日 20 時を目安に回答してもらうため、一日の区切りを 20 時にする。推定・予測にはそれぞれ機械学習を用いる。まず、前処理として、データの特徴量  $X$  は平均  $\mu$ 、分散  $\sigma$  から以下の式で標準化を行う。

$$z = \frac{X - \mu}{\sigma} \quad (3)$$

$\sigma = 0$  のときは、 $z = 0$  とする。

フィジカルヘルス、メンタルヘルスを推定・予測の対象とする。「フィジカルヘルス」は、表 1 の質問項目の「(a) 本日の身体の調子はよかった」、「メンタルヘルス」は「(b) 本日のメンタルの調子はよかった」の回答結果である。(a) は 1 日のフィジカルの状態、(b) は 1 日のメンタルの状態を総合的に判断した結果である。5 段階のリッカート尺度の 1-2 の値を「悪い」、3 の値を「普通」、4-5 の値を「良い」とした 3 クラスの分類問題として置き換えることにした。なお、目的変数の特徴量は、決定木による特徴量選択により、情報量の高い特徴量のみで学習モデルを構築する。健康状態が優れない日が頻繁に起こることは多くなく、「悪い」のラベルのデータが少なくなると考えられる。ラベルが不均一なデータはモデルの過学習を引き起こしやすく、識別性能の正確な評価が難しくなる。そこで、オーバーサンプリングを行うことによりラベルの数が不均一な状態から均一な状態へと整える。オーバーサンプリングには Synthetic Minority Over-sampling Technique (SMOTE) [11] を使用する。

## 4. 評価

本章では、提案手法の有効性を確認するための評価実験とその結果について述べる。

### 4.1 実験

ウェアラブル機器のライフログと体調の評価データを得るための実験を行った。実験では、Ecological Momentary Assessment (EMA) を採用し、被験者にウェアラブルデバイスを装着してもらい、普段の生活からデータを収集する。3.2 節で述べたアンケートアプリを各被験者自身が所有するスマートフォンにインストールし、毎日、20 時以降にアンケートに回答してもらう。実験には、10 名（男性、24.2±2.0 歳）が参加した。うち、Android ユーザは 4 名、iPhone ユーザは 6 名であり、約 1 ヶ月半に渡ってデータ収集実験を実施した。しかし、このうち 3 名の被験者に関しては、誤ったアプリの削除、スマートフォンの破損によりライフログの収集ができなかった。結果として、320 日分のライフログ（7 名分）が収集され、310 日分のアンケート回答（10 名分）が得られた。収集したヘルスデータのラベルの分布を表 3 に示す。データとしては、「普通」のラベルのデータが少なく、フィジカル、メンタル両方とも「良い」のラベルが全データの半数近くとなっている。

表 3 収集したヘルスデータのラベルの分布

Table 3 Distribution of labels of health data

種類	悪い	普通	良い
フィジカルヘルス	60	45	92
メンタルヘルス	62	47	88

### 4.2 分類器ごとのヘルスの推定・予測精度

ヘルスの推定・予測に適した分類器を調査するため、被験者ごとの推定・識別モデルを複数の機械学習アルゴリズムで構築し、1 つ抜き交差検証で評価した。分類器として、Decision Tree (DT), Gaussian Naive Bayes (NB), Random Forest (RF), Stochastic Gradient Descent (SGD), Support Vector Classification (SVC) の 5 種類のアルゴリズムを評価の対象とした。生活特徴の時間窓は  $h = 4$  とし、推定、予測ともに 4 日分の特徴量を用いた。


推定・識別結果を図 5 に示す。精度の指標は F 値とした。SGD と SVC の 2 種類の分類器の精度が他に比べて低く、対比的に、DT, NB, RF の 3 種類の分類器は良い精度で推定・識別できている。特に NB と RF は精度が高く、被験者ごとの精度の差も小さい。フィジカルヘルスの推定は RF で 80.51 ± 6.45%、フィジカルヘルスの予測は NB で 74.44 ± 11.50%、メンタルヘルスの推定は NB で 83.47 ± 8.96%、メンタルヘルスの予測は NB で 87.06 ± 13.59% がそれぞれにおいて最も精度の良い結果となっている。そして、若干ではあるが、フィジカルよりメンタルの精度の方が高い傾向にあることがわかる。

### 4.3 日数ごとのヘルスの推定・予測精度

次に、何日分の特徴量を含めるとヘルスの推定・予測向上に寄与するか、日数を 1 日から 7 日まで変化させて、精度の変化を検証する。評価方法は、被験者ごとの推定・識別モデルを構築し、1 つ抜き交差検証で評価した。分類器には Random Forest (RF) を利用し、特徴量の時間窓は  $h = 4$  とした。


推定・識別結果を図 7 に示す。1~2 日分の特徴量だと精度が低く、3~5 日分の特徴量で精度が最も高くなり、そして、6~7 日分の特徴量だと精度が下がっていることがある。この結果から、ヘルスの推定・予測精度を向上するには、少なくとも 3 日分のデータが必要なことがわかる。フィジカルヘルスの推定は 5 日分の 80.58 ± 8.87%、フィジカルヘルスの予測は 5 日分の 82.52 ± 14.66%、メンタルヘルスの推定は 7 日分の 85.91 ± 7.38%、メンタルヘルスの予測は 3 日分の 86.97 ± 7.81% がそれぞれにおいて最も精度の良い結果となっている。そして、こちらでもフィジカルよりメンタルの精度の方が高い傾向にあることがわかる。





(a-1) フィジカル：推定 (a-2) フィジカル：予測 (b-1) メンタル：推定 (b-2) メンタル：予測  
図 4 分類器ごとのヘルスの推定・予測精度

図 5 The accuracies of health estimation and prediction for each classifier.



(a-1) フィジカル：推定 (a-2) フィジカル：予測 (b-1) メンタル：推定 (b-2) メンタル：予測  
図 6 日数を変化させたときのヘルスの推定・予測精度

図 7 The accuracies of health estimation and prediction with changing the number of days.

## 5. まとめ

本研究では、数日間の生活のライフログから、心身の現在の健康状態を予測する手法と、翌日の健康状態を予測する機械学習に基づいた手法を提案し、その有効性を評価した。既存研究においては、直近の1日間のデータを使って健康状態を推定または予測する方法が主流であるのに対し、本研究では、数日間のデータにおける生活リズムや活動の周期性が健康状態に関わりを持つことに着目し、これらの分析結果を特徴量とした推定・予測手法を開発・評価したことが新規の貢献である。7人の実験参加者による320日分ライフログに提案手法を適用した結果、フィジカルヘルス、メンタルヘルスの現状の推定（悪い、普通、良いの3段階）において、それぞれ80.51%、83.47%のF値を達成した。また、予測においては、それぞれ、74.44%、87.06%のF値での予測ができることを確認した。さらに、特徴量として、過去3~4日のデータを使用することで、それより短いまたは長いデータを使用する場合と比べ、良い推定・予測精度が得られることが分かり、数日間のライフログからパターンを発見し特徴として使用する提案手法の有効性が確認できた。

## 参考文献

[1] Sano, A., Phillips, A.J., Amy, Z.Y., McHill, A.W., Taylor, S., Jaques, N., Czeisler, C.A., Klerman, E.B. and

Picard, R.W.: *Recognizing academic performance, sleep quality, stress level, and mental health using personality traits, wearable sensors and mobile phones*. 12th International Conference on Wearable and Implantable Body Sensor Networks (BSN), pp.1-6 (2015) IEEE.  
 [2] Rui Wang, Fanglin Chen, Zhenyu Chen, Tianxing Li, Gabriella Harari, Stefanie Tignor, Xia Zhou, Dror Ben-Zeev, and Andrew T Campbell.: *Studentlife: assessing mental health, academic performance and behavioral trends of college students using smartphones*. Proc. 2014 International Joint Conference on Pervasive and Ubiquitous Computing, pp. 3-14 (2014) ACM.  
 [3] Ciman, M. and Wac, K.: *Individuals' stress assessment using human-smartphone interaction analysis*. IEEE Trans. Affective Computing, Vol.9, pp.51-65 (2018) IEEE.  
 [4] Taylor, S.A., Jaques, N., Nosakhare, E., Sano, A. and Picard, R.: *Personalized Multitask Learning for Predicting Tomorrow's Mood, Stress, and Health*. IEEE Trans. Affective Computing, pp.14 (2017) IEEE.  
 [5] Rachuri, K.K., Musolesi, M., Mascolo, C., Rentfrow, P.J., Longworth, C. and Aucinas, A.: *EmotionSense: A Mobile Phones Based Adaptive Platform for Experimental Social Psychology Research*. Proc. 12th ACM International Conference on Ubiquitous Computing, pp.281-290 (2010) ACM.  
 [6] Bogomolov, A., Lepri, B. and Pianesi, F.: *Happiness recognition from mobile phone data*. International Conference on Social Computing (SocialCom), pp. 790-795 (2013) IEEE.  
 [7] Sun, D., Paredes, P. and Canny, J.: *MouStress: detecting stress from mouse motion*. Proc. SIGCHI conference on Human factors in Computing Systems (CHI '14), pp.61-70 (2014) ACM.

- [8] 鳥羽美奈子, 櫻井隆雄, 森靖英, 恵木正史: オフィスワークのストレス量と PC 操作ログ特徴量の重回帰分析— PC 操作ログ分析サービスの応用に向けて—, 情報処理学会デジタルプラクティス Vol.7, No.1, pp.71–79 (2016).
- [9] Lu, H., Frauendorfer, D., Rabbi, M., Mast, M.S., Chittaranjan, G.T., Campbell, A.T., Gatica-Perez, D. and Choudhury, T.: *StressSense: Detecting Stress in Unconstrained Acoustic Environments Using Smartphones*. Proc. ACM Conference on Ubiquitous Computing, pp.351–360 (2012) ACM.
- [10] Keller, A., Litzelman, K., Wisk, L, E., Maddox, T., Cheng, E, R., Creswell, P, D., Witt, W, P.: *Does the perception that stress affects health matter? The association with health and mortality*. Health Psychology, Vol.31,No.5, pp.677 (2012) American Psychological Association.
- [11] Chawla, Nitesh., Bowyer, K, W., Hall, L, O., Kegelmeyer, W P.: *SMOTE: synthetic minority oversampling technique* Journal of artificial intelligence research, Vol.16, pp.321–357 (2002).