

MyFactor：ユーザの内面状態に寄与する因子情報の個人特性に適応的な分析

小渕 幹夫^{2,a)} 西山 勇毅² 大越 匡² 米澤 拓郎² 中澤 仁¹

受付日 2016年12月23日, 採録日 2017年7月4日

概要：近年、様々なセンサを搭載したスマートフォンの発達と普及により、第三者による客観視が困難である「忙しい」や「疲れている」といった人間の内面状態の推定を行う研究が行われている。人間の内面状態を機械に認識させ、内面状態に寄与している因子に関する情報を人々に還元できれば、人間が自身の感情や気分を制御したり、特定の内面状態の獲得や回避といった行動変容へと応用可能である。しかし、人間の内面状態の認識・分析・還元においては、各個人の多様性に適応した動作の実現が課題である。本研究ではスマートフォンのセンサデータを蓄積し、正解データとなる内面状態の注釈をユーザが記録することで、個人の内面状態に寄与している因子を還元するために、因子情報を解析するシステム「MyFactor」を構築した。大学生13名による111日にわたる評価実験を行った結果、被験者全員のデータを用いて学習を行う「統合モデル」と比較して、各ユーザのデータのみを用いて個別に学習した「個人モデル」においては内面状態の推定精度が21%上昇した。また、利用可能なすべてのセンサからのデータを用いて学習した場合よりも、単一センサからのデータのみを用いて学習を行い、最も高精度で分類を行ったモデルを選択した方が高い推定精度を記録し、ユーザに自身の内面状態に関して深い理解を与える可能性を示した。

キーワード：ユビキタスコンピューティング、ライフログ、モバイルアプリケーション、機械学習、感情認識

MyFactor: Individual Characteristic Adaptive Estimation of Factor Information Contributing to Human Internal State

MIKIO OBUCHI^{2,a)} YUUKI NISHIYAMA² TADASHI OKOSHI² TAKURO YONEZAWA²
JIN NAKAZAWA¹

Received: December 23, 2016, Accepted: July 4, 2017

Abstract: Recently, due to the advance and spread of smartphones equipped with various sensors, human beings' inner states such as "busyness" or "tiredness" can be detected more accurately. If people can recognize the factors contributing to their inner states, they will be able to regulate their own emotions and moods by paying attention to those factors. However, the adaptive system for each individual's diversity that recognize, analyze, and provide the factors contributing to our inner state is not realized. In this research, we propose a system, MyFactor, that accumulates smartphone sensor data and user annotations about inner states to extract and provide information about the important factors contributing to a user's inner states. In a 111-day experiment with 13 university students, researchers estimated that an "individual model" developed only with the data of each user had a higher predictive accuracy for human inner states than the generic model developed using data from all subjects. In addition, the model with the highest predictive accuracy, trained by a single sensor, performed better and showed the possibility of giving a deeper understanding of human inner states than the model trained using data from all available sensors.

Keywords: ubiquitous computing, life-log, mobile application, machine learning, emotion recognition

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) fabius@ht.sfc.keio.ac.jp

1. はじめに

コンピューティングデバイスに搭載されている加速度センサやGPS、心拍センサといった様々なセンサを用いた人間の日常的な行動や状態を認識する多くの研究 [1], [2], [3], [4], [5] がさかに行われている。「歩く」や「座る」といった、人間の身体の物理的な動作や状態（外面状態）の検知には、多くの場合加速度センサやカメラが用いられている。一方で、人の感情や気分、感覚といった人間の内面状態を認知し、コンピュータに理解させるためにスマートフォンやウェアラブルデバイスから収集されたセンサデータを用いて人間の内面状態の推定を行う研究 [6], [7], [8], [9], [10], [11] も存在する。第三者による客観視が可能な事象と比べ、人間の感情や気分といった内面状態は、より内的な心の状態である。人の内面状態の推定が実現すれば、人間の内面状態に合わせたサービスを提供したり、感情や気分を家族や友人と共有することでより密接なコミュニケーションが実現可能になると考えられる。

関連して、人間の内面状態を機械に認識させ、特定の内面状態に寄与している因子に関する情報を人々に還元できれば、ユーザ自身の感情や気分を制御したり、人の特定の内面状態の獲得や回避といった行動変容へと応用可能である。身体的な行動を構成している因子、たとえば「歩く」という行動を構成している両足の動作に関する情報を人間に還元しても、その人にとって有益な真新しい情報の「気づき」を与えることは少ないと考えられる。一方で、人間の内面状態に寄与している因子、たとえば「快眠できた」と感じるための因子に関する情報が機械によって還元できれば、その情報を元に自身が快適に眠れるように環境を変化させたり、良質な睡眠をとるために日中行うべき行動の促進や、快眠できないと事前に分かれば必要に応じて薬剤を服用するといった行動変容が実現可能になると考えられる。

しかし、人間の内面状態の認識・分析・還元においては、各個人の性格等の多様性 [12] に対する適応的な動作の実現が課題である。人間ごとの多様性を考慮せず一般化された手法で内面状態に寄与している因子の抽出を行うと、異なる属性を持つ集団や国や文化の異なる人々には適応できず、検知性能が低下する恐れがある。個人によって好みの食べ物や映画が異なるように、同一の外的刺激が与えられた場合でも、人間の振舞いや反応は異なりうるため、各個人の特性を考慮した、ユーザに最適化された内面状態の因子に関する情報を抽出し還元することで、自身の内面状態に関する深い分析と理解を与えることができる。

本研究では各個人の行動パターンや特徴 [13], [14] が現れるスマートフォンのセンサデータを蓄積し、正解データとなる内面状態の注釈をユーザが記録することで、そのユーザがどのような1日を過ごし、その結果どのような

内面状態になったかという因果関係を解析するシステム「MyFactor」を構築した。大学生13名による111日にわたる実環境での利用を想定した評価実験を行い、「快眠できた日」、「疲労度が高い日」、「忙しい日」の3つの内面状態に寄与している因子を分析するための機械学習モデルを構築した。利用可能なセンサをすべて使用し、ユーザごとに学習を行った「個人モデル」では、快眠できた日を57.2%、「疲労度が高い日」を66.0%、「忙しい日」を60.7%の精度で推定を行った。この値は、被験者全員のデータを用いた総括的に学習を行った「統合モデル」よりもそれぞれ約4–6ポイント高い推定精度である。また、最も高い精度で推定を行った単一のセンサのみを用いて学習した個人モデルでは、「快眠できた日」を74.2%、「疲労度が高い日」を79.3%、「忙しい日」を78.7%の精度で推定した。

本論文は以下のように構成する。まず2章では、本研究で取り扱う人間の内面状態について整理し、人の内面状態の推定と還元の重要性について論じる。3章では、人間の内面状態に寄与している因子の情報を分析するためのシステムについて述べる。4章では、個人モデルと統合モデル、および単一センサによるモデルと複数センサによるモデルの推定精度比較のために行った実験について説明する。5章では、比較実験の結果と考察について述べる。6章では関連研究を紹介する。7章で本論文をまとめる。

2. 人間の内面状態

本章では人間の内面状態について説明し、本研究で取り扱う人の内面状態について述べる。次いで、人間の内面状態の推定から還元までの重要性について説明し、それらを達成する上での問題点を明らかにする。

2.1 対象とする内面状態

人間の「歩く」や「食べる」、「座っている」といった身体的な行動や状態を人間の外面状態とした場合、人の感情や気分といった内的な心の状態は、外部からの客観的な観察が困難な内面状態に分類される。人間の感情や気分を様々な次元や尺度によって分類する研究 [15], [16], [17], [18] が行われてきた。たとえば、Circumplex Mood Model [16] は、図1に示すように、快楽 (pleasure) 次元と活発 (activeness) 次元の2つの次元からなる感情モデルであり、人間の気分を幸福、リラックス、平静、退屈、苛立ち、ストレス、緊張、興奮の8種類に分類している。

また、人間の内面状態には、表1に示すように、「感情」(emotion) と「気分」(mood) の間に違いが存在する [18]。感情は特定のイベントに対する自発的な反応であり、数秒から数分という短い間持続するという性質がある。また、気分と比較すると、顔の表情や姿勢といった形で第三者による客観視が可能である場合があるという特徴を持つ。一方、気分は累積されたイベントに対する反応で、数時間か

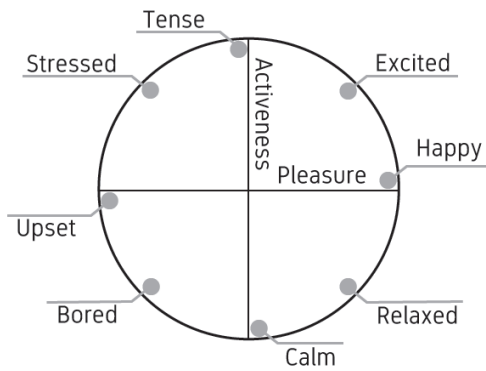


図 1 J. Russell の Circumplex Mood Model による感情の分類
 Fig. 1 J. Russell's circumplex mood model classification of emotions.

表 1 感情と気分の分類

Table 1 Distinctions between emotion and mood.

感情 (emotion)	気分 (mood)
数秒から数分持続	数時間から数日持続
特定のイベントに対する自発的な反応他人の目で確認できる事象	累積されたイベントに対する反応より内面的な事象

ら数日間という長時間持続する内面状態である。感情と比べると気分はより内的な [7] 心の状態を指すため、他人の目によって客観視することが困難な事象である。

本研究で取り扱う人間の内面状態は、ユーザが主観的に感じる 気分に焦点を当てる。その理由として、身体外部からの客観的かつ直接的なセンシングが困難な心の状態であり、感情よりもさらに内面的でユーザの心の根底に位置する事象 [7] であるからである。

2.2 内面状態の推定と因子情報の還元

人間の内面状態は主観的に決定されるものの、人間がその状態を認識しているとは限らない。そのため、機械を含む第三者によって各個人の現在の内面状態を推定し、その情報を提示することは人間に内省を促す。一方、人の内面状態の発生に関与している因子情報をユーザに還元することは、自身の内面状態に関するより深い理解を提供しうる。たとえば、ある人間が疲れているかどうかという情報を還元するよりも、疲れる原因となった因子に関する情報を還元する方が意味がある。自身の感情や気分を制御したり、特定の内面状態の獲得や回避といった行動変容へと応用可能である。

2.3 本研究が取り組む問題：因子情報の分析

しかし、人間の内面状態の認識・分析・還元においては、人間の性格等の多様性 [12] に対する適応的な動作が課題である。ユーザが日常的に利用し、膨大なデータが発せられるスマートフォン等のコンピューティングデバイスが普及 [19] する以前では、各個人に関するデータ収集量や手段が非常に限定的だった。そのため、すべての人間に一般化

された普遍的な手法 [6], [8], [10], [11] で内面状態に関係している因子の抽出を行っていたが、そのような手法では、異なる属性を持つ集団や国や文化の異なる人々には適応できず、抽出精度が低下する恐れがある。ユーザが導き出された因子情報を元に行動変容へと応用するには、提示された情報が信頼できるものであり、内面状態との関係性が認められるものである必要がある。同一の外的刺激が与えられた場合でも、人間の振舞いや反応は異なりうるため、各個人の特性を考慮し最適化された因子情報を導き出すことが重要であり、そういった個人に適応的な分析ができれば、ユーザは自身の内面状態をより理解することができると考えられる。本研究では、将来的な因子情報の還元までを見据えた上で、上記のような理由から、特に内面状態の寄与因子の個人特性に適応的な分析に焦点を当てる。

3. MyFactor システム

本章では、2章で述べた本研究で対象とする人間の内面状態に寄与している因子情報に関して、多様な個人の特性に適応的な分析を行うシステムである MyFactor について説明する。MyFactor で因子情報を分析することで、ユーザの自身に対する発見や気づきの提供や行動変容への応用が可能である。

3.1 特長

MyFactor は以下の4つの特長を持つ。第1に、生体センサ等を搭載した特殊デバイスを必要とせず、各個人のスマートフォン上で動作する。第2に、多様な個人に対応した因子情報を分析する。第3に、因子情報を人間が理解しやすい形で分析する。第4に、逐次的に因子を分析する。

3.1.1 スマートフォン上での動作

日常生活で発生するイベントの累積に対する反応である人の気分の寄与因子を分析するために、ユーザに関する情報を長時間にわたってセンシングする必要がある。脳波センサや心拍センサといった生体センサの着用はユーザにとって負担である。また、カメラによる写真撮影やビデオ撮影はユーザのプライバシーを侵害する可能性がある。そこで本研究では、長時間利用を考慮し、ユーザが日常的に使用するスマートフォンを用いたセンシングを行う。

3.1.2 多様な個人への適応

因子情報をユーザに還元する際、それが何らかの根拠に基づいて導き出されており、信憑性があることが前提条件である。人間の性格等の多様性に適応するため、MyFactor はすべての人間に対して1つのユニバーサルなモデルを構築するのではなく、個人ごとのデータのみを使用して最適化されたモデルを構築する。他のユーザのデータから分析された因子情報よりも、自身のデータを用いて分析した因子情報の方がユーザにとって解釈しやすく、信憑性を与えられると考えられる。

3.1.3 因子情報の理解

人間の機械学習への信頼獲得とそれに基づくシステム利用促進に関しては、透明性が高く、どのような変数が使用されているのか確実に認識できるようなモデルが好まれる傾向がある [20]. システムによって導き出された因子情報の確実性が高くても、その情報が難解であればユーザにとっての利益が小さくなる. そこで MyFactor では分析した因子情報をユーザへ還元しやすいよう、次の 3 つの性質をユーザの理解を支援するための重要な要素だと考える.

- **数値や方向の具体性**: ユーザが因子情報を元に行動を変容するには、因子が具体的にどのような値や方向へと変化すれば内面状態が変化するか説明する必要がある. 特徴ランキング等で抽出された、寄与している因子の名称だけでは不十分だと考える.
- **特徴量の分かりやすさ**: 内面状態を推定するモデルを構築する際、因子に対して何らかの特徴量計算を行う必要がある. たとえば、最大値や最小値、平均といった計算方法は多くの人にとって親しみ深いものであると推測できるが、尖度や歪度といった数値計算は専門性が高く大衆的でない.
- **モデルの平易さ**: 因子情報を還元する際、提供する情報量が膨大であったり、多様な種類の因子が複雑に交錯している情報では読み手にとって負担である可能性がある. 因子情報を明解にするためには、平易な因子情報の提示が重要であると考えられる.

MyFactor では、ユーザの因子情報に対する理解のしやすさを考慮し、決定木を用いた機械学習モデルを構築する. 決定木は if-then 形式のルール集合に変換することが可能であるため、ニューラルネットワークやサポートベクターマシンといった機械学習アルゴリズムよりも理解しやすいという特徴があげられる. また、内面状態に寄与している因子を提示するだけでなく、その因子をどのように変化させれば内面状態が変化するか具体的に読み取ることが可能である.

3.1.4 逐次分析

MyFactor は行動変容の促進を目的とした因子情報の還元を実現するため、1 日ごとにそれらの分析を行う. たとえば、数カ月から数年といった長期間のデータを収集し、その後分析をかけたユーザに情報を還元するのでは日常的な内省を実現できない. 一方で、数分から数時間ごとに情報を提供したり、正解データとなる内面状態の注釈を依頼するのは、利用者にとって負担である. また、数時間単位で注釈する場合、個人のライフスタイルによって時間帯によって注釈データ件数に偏りが生じてしまう可能性がある. そのため、本研究ではユーザが内面状態に関する正解データを 1 日単位で注釈することで、システムが追加で学習し、必要に応じて逐次因子の情報を確認できるようにする. 多くの人々が「先日は何をしたか」や「今日は何をし

ようか」と日単位で振り返りをしたり、予定を管理することに慣れていていると考えられる.

3.2 使用方法

ユーザが MyFactor を使用するには、まず自らのスマートフォンに MyFactor アプリケーションをインストールする. 本アプリケーションは iOS9.0 以上の OS が搭載された Apple 社の iPhone6 [21] 以降のデバイスで動作する. MyFactor 利用に際してユーザが求められることは、(a) アプリケーションの常時起動と (b) 正解データの作成の 2 点である. iOS ではアプリケーションが起動されていない場合、センサデータを収集することが仕様上不可能であるため、アプリケーションをバックグラウンドで常時起動しておく必要がある. また、ユーザの内面状態に寄与している因子を抽出するために、図 2 に示す画面で、自身の内面状態に関する正解ラベルを注釈することが求められる. 正解ラベルの注釈は、リッカート尺度 [22] を用いた 5 段階 (1 = “非常にそうである”, 2 = “そうである”, 3 = “どちらでもない”, 4 = “そうでない”, 5 = “非常にそうでない”) での主観的な選択を求める.

ユーザは図 3 に示すような、収集中のセンサデータをリアルタイムに確認したり、図 4 のように、蓄積された過去のセンサデータを見ることができる. また、ユーザの内面状態に寄与している因子の還元の第一歩として、図 5 に示すように、生成された決定木を閲覧することができる.

ユーザは任意のタイミングで因子情報を説明する決定木を閲覧して、その情報を自由に解釈し、自分の行動変容へ役立てることが可能である. 例としてシステムが「月曜日の朝は目覚めが悪いが、火曜日は目覚めが良い」といった情報をユーザに還元したとする. ユーザはその情報を元に各曜日の行動を思い浮かべたり、蓄積されているデータログを閲覧したり、MyFactor を使って別の因子との関係性を分析できる.

3.3 設計と実装

MyFactor のシステム概要を図 6 に示す. 本システムは、ユーザのスマートフォン上で動作する「MyFactor アプリケーション」と、センサデータおよび注釈データを蓄積し、機械学習によって因子の分析を行う「MyFactor サーバ」から構成される.

図 7 に、本システムのアーキテクチャ図を示す. 本システムはセンサデータ検知モジュール、気象データ取得モジュール、注釈データ取得モジュール、データ送信モジュール、データ保存モジュール、特徴量抽出モジュール、モデル構築モジュール、そして因子可視化モジュールから構成される. 以下に下記モジュールについて詳述する.

- **センサデータ検知モジュール**: 表 2 に示すスマートフォンに搭載されているセンサデータを 10 秒ごとに

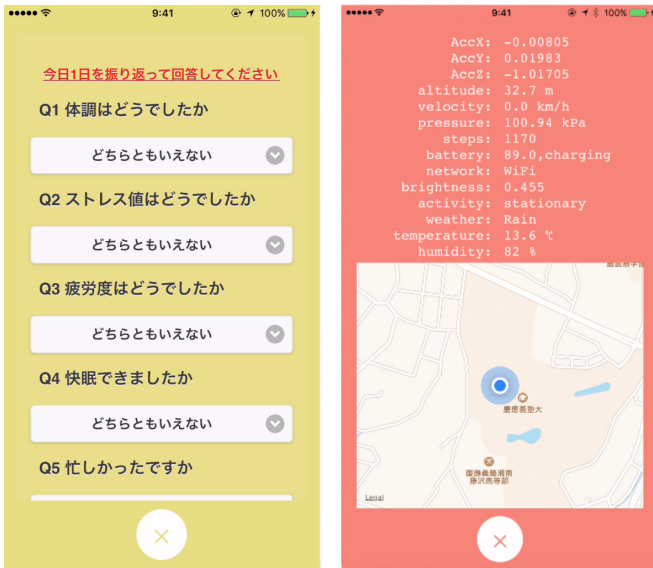


図 2 内面状態の注釈を行う画面 Fig. 2 Window to make the label of inner state.
 図 3 取得センサデータ表示画面 Fig. 3 Window to see the real time sensor data.




図 4 充電残量記録の閲覧画面 Fig. 4 Window to see the battery data.

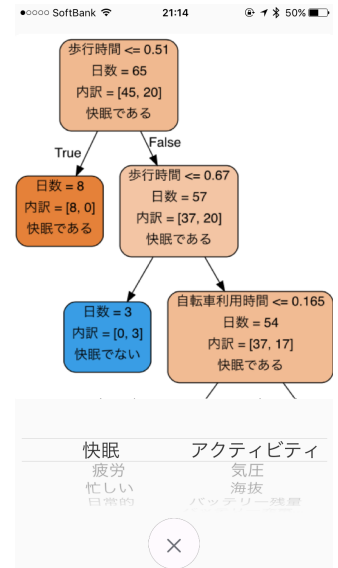


図 5 決定木閲覧画面 Fig. 5 Window to see the generated tree.

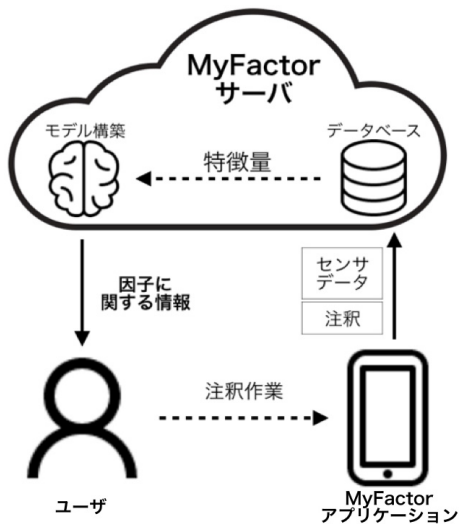


図 6 MyFactor システム概要 Fig. 6 MyFactor system overview.

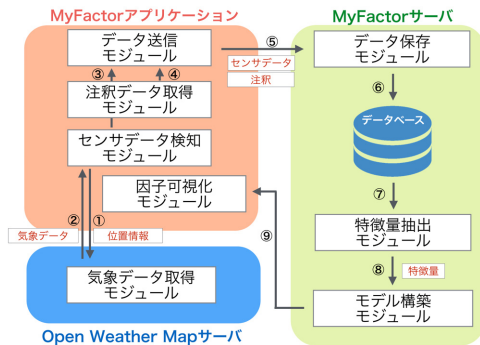


図 7 MyFactor システム構成図 Fig. 7 MyFactor system architecture.

取得し、端末上に保存する。どのセンサが人間の内面状態に寄与しているか事前に把握することができないため、iOS で提供されている利用可能なおおむねすべてのセンサを利用する。しかし、加速度やジャイロといったセンサは除外している。これはユーザにセンサデータを提供する際、人間が生データを理解しにくいと判断したためである。一方で、加速度やジャイロのデータを用いて算出していると考えられるユーザの「移動手段」や「移動速度」といった人間がより理解しやすいデータについては検知、記録する。

- 気象データ取得モジュール：Open Weather Map [23] API を利用し、ユーザの緯度・経度データを元に現在の地の天気、気温、湿度データを取得する。API によ

て提供されている気象情報の更新間隔は約 1 時間程度であり、ユーザがとある地域から別の地域に移動することも考慮し、データの取得間隔は 30 分とした。気象データはセンサデータと同様に端末上に記録される。

- 注釈データ取得モジュール：ユーザが主観的に感じた内面状態に関して注釈を作成するためのインタフェースを提供する。
- データ送信モジュール：スマートフォンに蓄積されたセンサデータ、気象データおよび注釈データを MyFactor サーバに送信する。データの送信は原則 1 時間ごとに行われるが、ユーザは WiFi 接続時のみに送信するよう設定することができる。通信が成功した場合端末に蓄積されているデータを削除する。
- データ保存モジュール：クライアント端末から送られてきたセンサデータおよび注釈データを MyFactor サーバのデータベースに格納する。
- 特徴量抽出モジュール：データベースに蓄積された

表 2 スマートフォンで収集するセンサデータ一覧
Table 2 List of sensors collected from smartphone.

センサ	データ種類
GPS	緯度, 経度, 海拔, 移動速度
気圧計	気圧
歩数センサ	歩数
スクリーン	スクリーン輝度
バッテリー	残量, 充電状態 (充電/非充電)
ネットワーク	接続モード (Wi-Fi/3G・4G 回線)
アクティビティ	移動手段 (静止/歩行/ランニング/自転車/交通)

表 3 各センサの特徴量の算出方法
Table 3 Features extracted from each sensors.

データ	出力形式	算出方法	
海拔	数値	1 日の最小値, 最大値 平均値, 標準偏差	
気圧			
バッテリー残量			
スクリーン輝度			
移動速度			
気温			
湿度			
曜日			曜日 id (0-6)
歩数			1 日の累計歩数
バッテリー充電状態			文字列
ネットワーク			
アクティビティ			

ユーザのスマートフォンから取得されたセンサデータおよび気象データを、機械学習で利用できるよう特徴量を算出する。表 3 に使用する特徴量を列挙する。ユーザによる内面状態の注釈は 1 日単位で作られるため、1 日に 1 件の学習データが得られる。

- **モデル構築モジュール**：抽出した特徴量を教師データとし、ユーザの手によって作成された内面状態に関する注釈を正解ラベルとした教師あり学習を行う。機械学習ライブラリは Python 言語で書かれた scikit-learn [24] (ver.0.17) を使用する。分類アルゴリズムには決定木 (CART [25]) を利用し、評価尺度にはジニ係数を用いる。調整可能なパラメータに関してはデフォルト値を用い、決定木の深さの最大数 (max_depth) および葉ノードに必要なサンプルの最小数 (min_samples_leaf) に対して制限を設けなかった。本研究では次に示すセンサデータの利用範囲の異なる 2 種類のモデルを構築する。
 - **単一センサによるモデル**：気圧センサや歩数計といった数あるセンサの中から 1 種類のみデータを使用して構築したモデルのことである。単一のセンサを利用することで、複数のセンサによって構築したモデルよりも特徴量の種類が少なく、読み取りやすいモデルになると考えられる。
 - **複数センサによるモデル**：利用可能なすべての種 (12 種) のセンサデータを利用して学習したモデルのことである。1 つのセンサによるモデルと比べて理解が

難しくなるという懸念があるが、単一のセンサのみのモデルと比べて有効な特徴量が存在した場合、高精度な分類ができる可能性がある。

決定木はアルゴリズム内部で特徴選択を行っているため、学習に用いられたすべての特徴量が出力された決定木に必ず登場するとは限らない。したがって複数センサによるモデルでは 12 種のセンサからいくつか有効な因子として適応的に抽出されるといえる。一方、単一センサによるモデルでは、それぞれの決定木を単体で見るとはならず、各モデルの推定精度といった性能指標を元に内面状態に寄与しているといえる因子とそうでない因子を比較し、選択するという段階が必要である。

なお、本研究では内面状態推定にあたって、上記の 2 つのモデル以外のセンサの種類 (2-11 種) を組み合わせたモデルは用意しない。機械学習モデルによって導き出された因子情報を還元するにあたって、可能な限りシンプルなモデルすることが好ましく、様々な種類のモデルを構築するのはユーザを混乱させる恐れがある。そのため、本研究では単一センサおよび利用可能なすべてのセンサを用いた場合の 2 種類のモデルの構築にとどまり、組合せ等の考察は対象としない。

- **因子可視化モジュール**：構築したモデルを元に、ユーザの内面状態に寄与している因子の情報をユーザが閲覧できるようにする。ユーザは因子を分析したい内面状態とモデルの種類をスマートフォンアプリケーション上で選択することができる。選択された内面状態とセンサのペアを元に、事前に生成された決定木画像が表示される。決定木全体を閲覧できるようにした理由は、機械学習モデルの訓練によって獲得された因子情報が、異なる可視化手法や情報提供方法へと変換する過程で、欠落したり損失しないようにするためである。なお、本研究は人間の内面状態に寄与している因子の還元のための、個人特性に適応的な推定と分析に焦点を当てるため、還元方法やその妥当性については次の段階と位置付ける。

4. 評価実験

本章では、MyFactor が多様な各ユーザの内面状態に寄与する因子情報を適応的に分析したか、その性能についての評価を行う。同評価を目的として、13 人による 111 日間の比較実験を実施した。決定木を用いて構築した個人モデルと統合モデルの交差検証による推定精度を比較する。

注釈を行う内面状態として (a) 「快眠できた日」、(b) 「疲労度が高い日」、(c) 「忙しい日」の 3 つを選択した。これらの内面状態に寄与する因子情報を認識することで、良質な快眠の獲得、疲労の軽減、多忙化の改善等、ユーザの健康管理や QOL の向上に役立てられると考えられる。実験

期間は 2015 年 12 月 15 日から 2016 年 4 月 4 日までの 111 日間である。

4.1 被験者

本実験での被験者として、iOS 端末を主たるスマートフォンとして日常的に利用している大学生 13 名（男性 9 名および女性 4 名）の協力を得た。実験開始日における被験者らの年齢は 19 歳から 23 歳であり、平均年齢は 20.9 歳であった。

4.2 実験手順

実験開始日に、実験に関する説明を各被験者に行い、被験者が各自、日常的に使用する iOS スマートフォンに MyFactor アプリケーションをインストールする。以降の実験期間中、毎日朝 7 時に「快眠できた日」であるか、23 時 30 分に「疲労度の高い日」、「忙しい日」であったか注釈を要求する通知をスマートフォン上に表示し、各被験者は 3 つの内面状態に関して正解ラベルの注釈を行う。

4.3 モデルの構築と推定精度

実験期間終了後、複数センサと単一センサそれぞれにおいて個人モデルと統合モデルの計 4 種類の機械学習モデルを構築する。

個人モデルは leave-one-day-out 方式の交差検証によって推定精度を算出する。任意のユーザの教師データ数を k 日分とした場合、そのなかから 1 件をテストデータとして抜き出す。その後、 $k-1$ 件の教師データで学習を行った機械学習モデルによって抜き出したテストデータのラベルを予測する。これをすべてのデータが 1 回ずつテストデータになるよう合計 k 回実行し、正答率を最終的なスコアとする。

一方、統合モデルの推定精度は leave-one-user-out 方式の交差検証によって算出する。個人モデルが 1 日分のデータをテストデータとして抽出したのに対し、統合モデルの評価では被験者 13 人から 1 人分のデータを抽出し、12 人分の教師データで訓練したモデルを用いてそのユーザの各日付の正解ラベルの予測を行い、推定精度を算出する。

アプリケーションをバックグラウンド起動していなかったり、スマートフォンのバッテリー切れ等によってデータ

のセンシングが停止し、収集されたセンサデータ量が 1 日の 80% (19.2 時間) に満たない場合、同日のデータはすべて利用しない。また、ユーザが内面状態に関する注釈を作成しなかった日のデータも学習に用いない。1 人あたりの学習データサンプル数が少なくなる問題が予想されるため、注釈どおりの 5 段階の分類問題ではなく、表 4 のように正解ラベルに対して前処理を行い、内面状態が“高い” = 1 または“低い” = 0 のどちらかに分類を行うものとする。リッカート尺度を用いていることから「非常にそうである」は「そうである」の延長にある事象であると解釈できるため、双方をまとめて学習して提示しても内面状態の獲得や回避に必要な情報が提供できると考えられるが、ユーザを混乱させないよう正解ラベルの前処理についての説明も行った。

5. 実験結果と考察

本章では、実験結果に基づく分析とその考察を行う。実験を行った結果、延べ 1,039 日間分のセンサデータと 2,600 件の注釈データが収集された。この数値を実験期間中に理論上収集可能な最大の量と比較した場合、実際に得られたデータの割合はセンサデータが約 72%、注釈データが約 60%となる。図 8 は、実験期間中に集められた各被験者の注釈データ件数の分布を表す。

5.1 複数センサによるモデル

表 5 は、複数センサからのデータによる個人モデルと統合モデルの推定精度を示す。




図 8 実験期間中の各被験者の注釈データ件数

Fig. 8 The number of annotations of each participants during the experiment.

表 4 正解ラベルの前処理
Table 4 Preprocessing of labels.

処理前	処理後
非常にそうである	1
そうである	
どちらでもない	※除外
そうでない	
非常にそうでない	0

表 5 複数センサによるモデルの推定精度の平均と標準偏差
Table 5 Comparison of average and standard deviation of predictive accuracy trained with multiple sensor.

	快眠できた日	疲労度が高い日	忙しい日
個人モデルの平均 (標準偏差)	57.2% (12.7)	66.0% (14.5)	60.2% (14.3)
統合モデルの平均 (標準偏差)	52.9% (9.8)	59.7% (7.3)	56.5% (8.2)

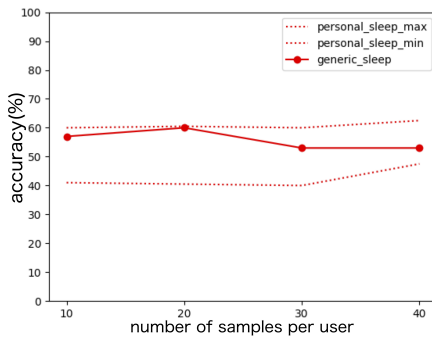


図 9 「快眠できた日」の推定精度の推移

Fig. 9 Transition of predictive accuracy for sleep.




図 10 「疲労度の高い日」の推定精度の推移

Fig. 10 Transition of predictive accuracy for tiredness.

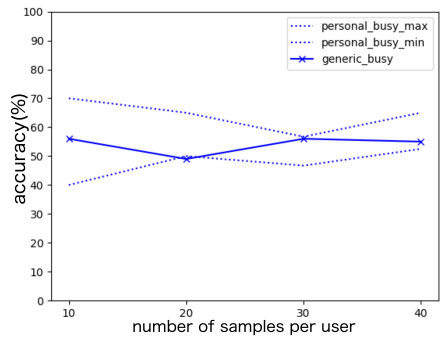


図 11 「忙しい日」の推定精度の推移

Fig. 11 Transition of predictive accuracy for busyness.

5.1.1 推定精度の比較

最も高い推定精度を示したのは、「疲労度が高い日」を個人モデルで推定した場合のモデルで、精度は 66.0% だった。推定精度が最も低かったのは、「快眠できた日」を統合モデルで推定した場合のモデルだった。今回選定した内面状態 3 件すべてにおいて個人モデルの方が統合モデルよりも高い推定精度を記録した。個人モデルの方が推定精度が高かった理由として、ユーザの行動やライフスタイル、パーソナリティが考慮されていることがあげられる。個人モデルが統合モデルと比べて平均 5.3 ポイント高い推定精度を記録した一方、これらのモデルの性能は多くが 50% 台であり、高い精度であるとはいいがたく、一般化するのは難しいと考えられる。今回の内面状態推定は二値分類問題であり、モデルの推定精度が 50% に近いほど、推定したい内面状態が「Yes」である確率と「No」である確率が近くなるため、1/2 の確率でランダムに内面状態ラベルを予測しているのと同様の挙動であり、実質的に有効な特徴量を見つけれなかったことを意味する。

また、統合モデルよりも個人モデルの方が標準偏差が大きいという結果が得られた。このような結果になった理由として、個人モデルの学習データ数に対し、複数センサによるモデルの特徴量の数が多いことがあげられる。一般的に、モデルの説明変数が増加するほど、学習データのノイズに適合しやすくなるという問題がある。したがって個人モデルではデータ量の多い統合モデルと比べて、有効な特徴量を誤ってしまう可能性があり、有効な特徴量が存在する被験者とそうでない被験者で推定精度の差が生じたと考えられる。

5.1.2 推定精度と学習コスト

統合モデルは個人モデルと比べて、単位時間あたりに収集できる教師データ量が多いため、短期間であってもモデル学習に十分な量のデータを収集することができる。しかし、個人の多様性があるため、必ずしもデータ量が多いほど推定精度が高くなることを意味するとは限らない。図 9、図 10、図 11 は、教師データ数と推定精度の推移を示し

たものであり、点線は個人モデルの最大値と最小値、実線は統合モデルを表している。我々は教師データ収集期間が長くなるに従って、個人モデルでも十分なデータが集まり、個人モデルの推定精度が統合モデルを下から追い抜く形になると予想していた。しかしながら、学習コストと推定精度はトレードオフの関係にあるという予測に対し、今回の実験期間中にそのような関係性は確認されなかった。MyFactor における学習コストと推定精度の関係性を明らかにするには、統合モデルを構築するための被験者数を増加し、さらに長期的な実験を行いながら分析された因子情報がどのように変化していくか経過観察する必要がある。

5.2 単一センサによるモデル

3 つの内面状態において、それぞれ 12 種類のセンサを用いて個人モデルと統合モデルを計 36 組構築した。図 12、図 13、図 14、図 15、図 16、図 17、図 18、図 19、図 20、図 21、図 22、図 23 は各センサデータによる個人モデルと統合モデルの推定精度を示している。

5.2.1 推定精度の比較

36 組のうち 34 組において、個人モデルの方が統合モデルよりも高い推定精度を記録した。個人モデルおよび統合モデルの両方において、「快眠できた日」を曜日で推定した場合が最も高い推定精度を記録し、個人モデルにおいては 70% を超えている。これは被験者らが、快眠できるかどうか曜日に依存していることを意味すると推測できる。

単一センサの場合も複数センサのケースと同様、個人モデルの方がユーザの特性を考慮していると考えられる。例として、「忙しい日」であるかを歩数を用いて推定した個人モデルの場合は、全体の中で 2 番目に精度が高い (67.1%) が、統合モデルの方では精度は 12 ポイント以上も低くなっている。これは個人によって忙しい日の感じ方が異なり、たとえば、予定が非常に多く、次の目的地へと歩けば歩くほど忙しく感じる人がいる一方で、まったく歩かずに家や職場でひたすら業務にのめり込むことで忙しく感じる人がいるかもしれない。




図 12 海拔による推定精度比較

Fig. 12 Comparison of predictive accuracy using altitude.




図 13 気圧による推定精度比較

Fig. 13 Comparison of predictive accuracy using air pressure.




図 14 バッテリー残量による推定精度比較

Fig. 14 Comparison of predictive accuracy using battery remain.




図 15 スクリーン輝度による推定精度比較

Fig. 15 Comparison of predictive accuracy using brightness.




図 16 移動速度による推定精度比較

Fig. 16 Comparison of predictive accuracy using velocity.




図 17 気温による推定精度比較

Fig. 17 Comparison of predictive accuracy using temperature.




図 18 湿度による推定精度比較

Fig. 18 Comparison of predictive accuracy using humidity.




図 19 歩数による推定精度比較

Fig. 19 Comparison of predictive accuracy using steps.




図 20 バッテリー充電状態による推定精度比較

Fig. 20 Comparison of predictive accuracy using charging state.




図 21 ネットワーク接続による推定精度比較

Fig. 21 Comparison of predictive accuracy using network.




図 22 移動手段による推定精度比較

Fig. 22 Comparison of predictive accuracy using activity.




図 23 曜日による推定精度比較

Fig. 23 Comparison of predictive accuracy using day of week.

表 7 各ユーザの最も高い推定精度とセンサ名

Table 7 Highest predictive accuracy and sensor of each users.

	快眠できた日	疲労度が高い日	忙しい日
user1	76.2% バッテリー充電状態	75.0% スクリーン輝度	80.8% ネットワーク接続
user2	74.1% 気温	76.9% スクリーン輝度	78.5% ネットワーク接続
user3	74.6% スクリーン輝度	85.2% 曜日	69.4% 移動手段
user4	67.4% 曜日	87.1% 移動手段	76.7% 曜日
user5	73.3% ネットワーク接続	80.2% 歩数	74.0% 移動速度
user6	63.6% バッテリー残量	82.4% 歩数	100% 歩数
user7	63.8% ネットワーク接続	82.9% 移動手段	78.4% 曜日
user8	80.7% 気温	76.5% 歩数	76.5% 曜日
user9	66.3% バッテリー残量	76.7% 曜日	81.4% 湿度
user10	84.2% 気圧	70.0% 湿度	77.3% 湿度
user11	72.9% 海拔	76.0% 歩数	72.0% 気温
user12	83.5% 湿度	69.2% 曜日	79.2% 曜日
user13	84.2% バッテリー充電状態	92.3% 移動速度	79.2% 移動速度
平均 (標準偏差)	74.2% (7.4)	79.3% (6.6)	78.7% (7.2)

表 6 最も頻出回数の多かった最上部の葉ノードに登場する特徴量

Table 6 Features in the uppermost leaf node that most frequently appeared.

	快眠できた日	疲労度が高い日	忙しい日
海拔	平均	標準偏差	最大
気圧	平均	標準偏差	標準偏差
バッテリー残量	平均	平均	最小
スクリーン輝度	平均	標準偏差	平均
移動速度	標準偏差	平均	平均
気温	標準偏差	平均	最小
湿度	平均	平均	平均
移動手段	交通	歩行	静止

一方で、湿度およびバッテリー充電状態でそれぞれ「疲労度の高い日」を推定した場合は、個人モデルよりも統合モデルの方が推定精度が高かった。この2つの個人モデルは全体の中で最も推定精度の低い2つであり、統合モデルの推定精度との差も約2ポイントと小さく、ユーザの疲労度を推定するにあたって有効な特徴量ではないと考えられる。たとえば、あるユーザがスマートフォンを充電している時間が長い日も短い日もほぼ同頻度で「疲労度が高い」と注釈した場合、充電時間情報のみを用いて疲労度を推定するのは困難である。しかし、被験者全員のデータを総括的に学習した場合、充電時間情報と疲労度の間に重要な関係性を発見したユーザのデータが含まれていた場合、個人モデルよりも教師データ数の多い統合モデルの方が高い推定精度を導き出す可能性がある。

5.2.2 有効な特徴量

また、決定木の最上部にある葉ノードに登場する特徴量のうち、最も頻出回数の多かった特徴量を表6に示す。3つの内面状態において、同一の特徴量が用いられていたのは「湿度の平均値」のみであった。このことから同じセンサであっても、内面状態によって推定に用いられる特徴量

の算出方法は異なりうると解釈できる。平均値や標準偏差が比較的有効な算出方法だと読み取れる一方、最小値や最大値の頻出回数は少なかった。この理由として、センサデータの値の取りうる範囲とユーザの日常行動が関係していると考えられる。例として、多くのユーザは1日の中で移動しない時間があったり、スマートフォンのバッテリーをフル充電するという習慣があるとする。したがって原則として移動手段の最小値は0km/h、バッテリー残量の最大値は100%という値が毎日得られ、この情報を元に分岐を作ることが困難になる。一方、平均値や標準偏差は一意に決定されず、ユーザの日常行動によって柔軟に変化するため、内面状態を推定するにあたって有効な特徴量になりうると考えられる。

5.3 最高推定精度を記録した単一センサによるモデル

表7は、各ユーザの最も推定精度の高かった単一センサによる個人モデルの推定精度とセンサ名を示している。最も高精度で予測を行ったセンサのみを抽出した場合、これらすべての内面状態において推定精度の平均が70%台を記録し、「疲労度が高い日」と「忙しい日」に関しては80%に近い値となっていることから、これらはユーザの内面状態に少なからず影響を及ぼしている重要な因子であると考えられる。13人の被験者について、「快眠できた日」推定に使用されたセンサは9種類、「疲労度が高い日」については6種類、「忙しい日」については7種類であり、人間の内面状態を推定するのに最も有効なセンサがユーザごとに非常に異なることが分かる。これはユーザの内面状態推定において特徴が出やすいセンサデータが、個人のライフスタイルや行動パターンによって大きく異なるからだと考えられる。




図 24 疑似相関の例

Fig. 24 Example of spurious correlation.




図 25 間接効果の例

Fig. 25 Example of indirect effect.

5.4 抽出された因子の解釈

一方、今回の実験結果で導き出された内面状態とセンサデータの組合せの中には、因果関係を客観的に解釈しやすいものとそうでないものが存在する。客観的に解釈しやすい例として、たとえば、歩数と「疲労度の高い日」があげられる。歩数が何歩以上（もしくは以下）であれば疲労を感じるかという絶対的な値は個人によって異なりうるものの、「歩く」という行動は少なからず身体的な疲労に寄与しているだろうと解釈することができる。一方でたとえば、海拔と「快眠できた日」の関係性を客観的に解釈するのは容易ではない。今回の実験でそのような一見解釈しにくいセンサデータと内面状態の関係性に強い関係性があると算出された理由として、a) 疑似相関、b) 間接効果、c) 偶然の一致の3つの可能性が考えられる。

5.4.1 疑似相関

1つ目の可能性は疑似相関である。疑似相関とは、変数 A と変数 B の間に因果関係があるように推測された場合において、実際にその関係は別の変数 C が A, B それぞれに影響を及ぼしていることである。海拔（変数 A）と「快眠できた日」(変数 B) の関係性が疑似相関であると仮定した場合、例として、「自宅で寝るか」(変数 C) という要素が潜在的に存在し、海拔および快眠に影響を及ぼしている場合が考えられる（図 24）。自宅で寝ると快眠できる人間の場合、自宅で寝るかどうか、海拔および快眠の双方の変数を変化させており、直接的に海拔が快眠に影響を与えているわけではない。

5.4.2 間接効果

2つ目の可能性は間接効果である。間接効果とは、変数 A と変数 B の間に因果関係があるように推測された場合において、実際にその関係は変数 A が媒介変数 D に影響を及ぼしており、媒介変数 M の変化が B に影響を及ぼしていることである。海拔（変数 A）と「快眠できた日」(変数 B) の関係性が間接効果であると仮定した場合、例として、空気中の「酸素濃度」(変数 D) という要素が間に存在し、海拔が変化すれば酸素濃度が変化するため、酸素濃度の変化が結果的に人間の快眠に影響を及ぼしている場合が考えられる（図 25）。海拔が意味する地理的な要因ではなく、仮に海拔がどのように変化した場合でも、酸素濃度の変化によって快眠できるかどうか決定する場合が間接効果である。

5.4.3 偶然の一致

3つ目に、因果関係または共通の要因も存在しない偶然の一致の可能性が考えられる。例として、「スマートフォン普及率の向上」と「地球温暖化の進行」があげられる。過去数年において、どちらも確認できる事象で、統計上相関があると算出できるかもしれないが、2つの間に関係性があるとは考えにくい。偶然の一致であると考えられる。

推定精度が高く、MyFactor によって内面状態に寄与していると判断された因子の中には、その値が変化したからといって直接的に人の内面状態に影響を及ぼさないものも存在する。しかし、ユーザの日常行動の中で、特に表 7 に示したセンサと個人の内面状態の間には機械学習アルゴリズムが示す精度を参照することによって、双方間の関係性が捕捉されていると考える。

人の内面状態は累積されたイベントから複雑に決定されることから、直接的に寄与している因子を抽出するのは困難である。しかしながら、多様な各個人の行動パターンやライフスタイルの特徴が表れるスマートフォンのセンサデータによって関連する因子を分析し、ユーザに還元することによってユーザに「気づき」を与え、自身の内面状態の制御や行動変容に応用できると考えられる。

6. 関連研究

本章では、本研究に関連する研究について紹介する。

6.1 内面状態の推定

Bogomolov ら [10] は同じ大学の寮に住む被験者 117 人のスマートフォンの利用状況と気象データ、そしてユーザの性格データを利用してユーザのストレスを検知している。特殊な装置の装着を必要とせず、スマートフォンを利用するだけで自動的にストレス値を検出できるようになることで、ユーザがストレスの原因となる行動を避けたり、自分のストレスを管理できるようになると述べている。1日の終わりに自身のストレス値に関して注釈をつけてもらい、Random Forest による機械学習モデルを構築した結果、分類精度は 72.28%であった。ストレスという第三者による客観的な観察が困難な人間の内面状態を対象としている部分は本研究と類似する。しかし、MyFactor は人間の内面状態を推定するだけでなく、因子情報を還元することを見据えて、寄与している因子とその値がどのようなときに特

定の内面状態が発生するかまで分析を行っている。

Hammer ら [6] は、スマートフォン上で使用中のアプリケーション名やネットワーク接続といった情報を用いて被験者が「忙しいか (isBusy)」、「ストレスを感じているか (isStressful)」、「1人であるか (isAlone)」、「幸せか (isHappy)」という4つの状態をセンシングしている。被験者は一定時間ごとにスマートフォン上で自身の内面状態に関して注釈作業を行い、実験期間終了後、主成分分析を用いて最適な特徴量を選択することで、isHappy といったユーザの主観的な状態の推定を行っている。人間の内面状態を対象にしている部分は本研究に類似するが、本研究は一定期間経過後にデータを分析するのではなく、ユーザの注釈が作成される度に学習を行い、モデルを逐次更新し、ユーザに自身の内面状態に関する分析と理解を提供する。

また、どちらの研究も、1つで複数のユーザに対応する共通のモデルを構築するために、学習データを総括的に利用している。本研究では多様な人間の内面状態に適応すべく、ユーザごとに学習を行い、個人に最適化された因子の情報の提供を目指している。

6.2 因子の分析

SmartGPA [26] は大学生の学業成績 (GPA スコア) をスマートフォンのセンサデータを用いて予測する。はじめにスマートフォンに搭載されているセンサから収集されたセンサデータより、「図書館で勉強している時間」や「パーティーに参加している時間」等の時間を推定する。そして、作成された特徴量それぞれと GPA スコアとの相関係数を算出することで、学業成績の優良な大学生が行う行動と、そうでない学生が行う行動を発見した。分析対象は違うものの、特定の事象についてスマートフォンのセンサデータを元に寄与している因子を導き出すという点は本研究と類似する。しかし、算出された相関係数は説明変数と目的変数の間にある線形な関係を示す尺度であるため、非線形な関係を表すことができない。たとえば、肥満度 (BMI) と癌の発生率 [27] には二次関数のような関係があり、痩せているグループと太っているグループの発癌率が高くなる U 字型の関係性があるが、相関係数で直接的にその関係性を見出すことはできない。

Bogomolov ら [10] は機械学習で利用するデータの事前処理として使われる「特徴選択」を用いて、ユーザのストレス値を推定するのに有効な変数 (センサデータ) のランキングを導き出している。人間の内面状態に寄与している因子を分析している点は本研究と類似しているが、その因子の値がどのように変化したときに内面状態に影響が与えられるかという部分までの分析は行われていない。

一方、本研究では決定木による機械学習モデルを構築することで、説明変数と目的変数の間にあるより複雑な関係に関して分析を行うことができる。

7. おわりに

本研究では、多様な人間に適応した内面状態に寄与している因子情報を分析するシステムである MyFactor を構築し、推定精度に関する評価を行った。多様な個人に最適化された因子情報の抽出を行えたかを明らかにするために、被験者 13 人による 111 日にわたる実験を実施し、「快眠できた日」、「疲労度が高い日」、「忙しい日」の3種類のユーザの内面状態に寄与している因子に関する分析を行った。実験の結果、単体で全ユーザについての推定を行う統合モデルよりも、個人ごとに学習を行った個人モデルの方が高い推定精度を記録した。

今後の研究課題として、因子情報の還元手法の検討と行動変容に向けてのユーザビリティ評価があげられる。ユーザに発見と気づきを与える因子情報の中でも、特に重要なものを迅速に読み解くのを支援し、行動変容を促進するのに有効な還元方法を検討していく。

謝辞 本研究の一部は国立研究開発法人情報通信研究機構に支援いただいた。本研究の一部は国立研究開発法人理化学研究所に支援いただいた。本研究の一部は文部科学省・博士課程教育リーディングプログラム慶應義塾大学「グローバル環境システムリーダープログラム (GESL)」からの助成を受けたものです。

参考文献

- [1] Lester, J., Choudhury, T. and Borriello, G.: A Practical Approach to Recognizing Physical Activities, *Proc. 4th International Conference on Pervasive Computing, PERVASIVE'06*, pp.1–16 (2006).
- [2] Kim, E., Helal, S. and Cook, D.: Human Activity Recognition and Pattern Discovery, *IEEE Pervasive Computing*, Vol.9, No.1, pp.48–53 (online), DOI: 10.1109/MPRV.2010.7 (2010).
- [3] Bao, L. and Intille, S.S.: *Pervasive Computing: Second International Conference, Proc. PERVASIVE 2004, Linz/Vienna, Austria, April 21–23, 2004*, chapter Activity Recognition from User-Annotated Acceleration Data, pp.1–17, Springer Berlin Heidelberg (2004).
- [4] Min, J.-K., Doryab, A., Wiese, J., Amini, S., Zimmerman, J. and Hong, J.I.: Toss ‘N’ Turn: Smartphone As Sleep and Sleep Quality Detector, *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, CHI '14*, pp.477–486, ACM (online), DOI: 10.1145/2556288.2557220 (2014).
- [5] Sano, A. and Picard, R.W.: Stress Recognition Using Wearable Sensors and Mobile Phones, *Proc. 2013 Humaine Association Conference on Affective Computing and Intelligent Interaction, ACII '13*, pp.671–676, IEEE Computer Society (online), DOI: 10.1109/ACII.2013.117 (2013).
- [6] Hammer, J.C. and Yan, T.: Exploiting Usage Statistics for Energy-efficient Logical Status Inference on Mobile Phones, *Proc. 2014 ACM International Symposium on Wearable Computers, ISWC '14*, pp.35–42, ACM (online), DOI: 10.1145/2634317.2634325 (2014).
- [7] LiKamWa, R., Liu, Y., Lane, N.D. and Zhong, L.:

- MoodScope: Building a Mood Sensor from Smartphone Usage Patterns, *Proc. 11th Annual International Conference on Mobile Systems, Applications, and Services, MobiSys '13*, pp.389–402, ACM (online), DOI: 10.1145/2462456.2464449 (2013).
- [8] Bogomolov, A., Lepri, B. and Pianesi, F.: Happiness recognition from mobile phone data, *2013 International Conference on Social Computing (SocialCom)*, pp.790–795, IEEE (2013).
- [9] 小淵幹夫, 古川侑紀, 西山勇毅, 大越 匡, 米澤拓郎, 中澤仁, 高汐一紀, 徳田英幸: MyFactor: ライフログを用いたユーザの内面状態に関する因子分析, 研究報告ユビキタスコンピューティングシステム (UBI), Vol.2016-UBI-4, No.10, pp.1–6 (2016).
- [10] Bogomolov, A., Lepri, B., Ferron, M., Pianesi, F. and Pentland, A.: Daily Stress Recognition from Mobile Phone Data, Weather Conditions and Individual Traits, *CoRR*, Vol.abs/1410.5816 (online), available from <http://arxiv.org/abs/1410.5816> (2014).
- [11] Pielot, M., Dingler, T., Pedro, J.S. and Oliver, N.: When Attention is Not Scarce - Detecting Boredom from Mobile Phone Usage, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '15*, pp.825–836, ACM (online), DOI: 10.1145/2750858.2804252 (2015).
- [12] Rabbi, M., Aung, M.H., Zhang, M. and Choudhury, T.: MyBehavior: Automatic Personalized Health Feedback from User Behaviors and Preferences Using Smartphones, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '15*, pp.707–718, ACM (online), DOI: 10.1145/2750858.2805840 (2015).
- [13] Zhao, S., Ramos, J., Tao, J., Jiang, Z., Li, S., Wu, Z., Pan, G. and Dey, A.K.: Discovering Different Kinds of Smartphone Users Through Their Application Usage Behaviors, *Proc. 2016 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '16*, pp.498–509, ACM (online), DOI: 10.1145/2971648.2971696 (2016).
- [14] Srinivasan, V., Moghaddam, S., Mukherji, A., Rachuri, K.K., Xu, C. and Tapia, E.M.: MobileMiner: Mining Your Frequent Patterns on Your Phone, *Proc. 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '14*, pp.389–400, ACM (online), DOI: 10.1145/2632048.2632052 (2014).
- [15] Plutchik, R.: The Nature of Emotions, *American Scientist*, Vol.89, p.344 (online), DOI: 10.1511/2001.4.344 (2001).
- [16] Russell, J.: A circumplex model of affect, *Journal of Personality and Social Psychology*, Vol.39, No.6, pp.1161–1178 (1980).
- [17] Ekman, P., Friesen, W.V., O'Sullivan, M., Chan, A., Diacoyanni-Tarlatzis, I., Heider, K., Krause, R., LeCompte, W.A., Pitcairn, T., Ricci-Bitti, P.E., et al.: Universals and cultural differences in the judgments of facial expressions of emotion, *Journal of Personality and Social Psychology*, Vol.53, No.4, p.712 (1987).
- [18] Beedie, C., Terry, P. and Lane, A.: Distinctions between emotion and mood, *Cognition & Emotion*, Vol.19, No.6, pp.847–878 (2005).
- [19] 総務省: 平成 27 年度版情報通信白書, 入手先 <http://www.soumu.go.jp/johotsusintokei/whitepaper/h27.html> (参照 2016-12-09).
- [20] Behl, M., Jain, A. and Mangharam, R.: Data-Driven Modeling, Control and Tools for Cyber-Physical Energy Systems, *CoRR*, Vol.abs/1601.05164 (online), available from <http://arxiv.org/abs/1601.05164> (2016).
- [21] Apple Inc.: iPhone (2016), available from <http://www.apple.com/iphone/>.
- [22] Likert, R.: A Technique for the Measurement of Attitudes, *Archives of Psychology*, Vol.142, pp.1–55 (1932).
- [23] OpenWeatherMap, available from <http://openweathermap.org/> (accessed 2016-12-23).
- [24] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E.: Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Res.*, Vol.12, pp.2825–2830 (2011).
- [25] Breiman, L., Friedman, J., Stone, C.J. and Olshen, R.A.: *Classification and regression trees*, CRC press (1984).
- [26] Wang, R., Harari, G., Hao, P., Zhou, X. and Campbell, A.T.: SmartGPA: How Smartphones Can Assess and Predict Academic Performance of College Students, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing, UbiComp '15*, pp.295–306, ACM (online), DOI: 10.1145/2750858.2804251 (2015).
- [27] Inoue, M., Sobue, T. and Tsugane, S.: Impact of Body Mass Index on the Risk of Total Cancer Incidence and Mortality Among Middle-Aged Japanese: Data from a Large-Scale Population-Based Cohort Study – The JPHC Study, *Cancer Causes & Control*, Vol.15, No.7, pp.671–680 (online), DOI: 10.1023/B:CACO.0000036177.77953.47 (2004).



小淵 幹夫

1994 年生。2016 年慶應義塾大学環境情報学部卒業。現在、慶應義塾大学大学院政策・メディア研究科修士課程。主に、ユビキタスコンピューティング、アフェクティブコンピューティングの研究に従事。ACM, IEEE 各会員。



西山 勇毅 (学生会員)

1989 年生。2014 年慶應義塾大学大学院政策・メディア研究科修士。現在、慶應義塾大学大学院政策・メディア研究科後期博士課程および Global Environmental System Leaders (GESL) プログラム研究員。主に、ユビキタスコンピューティング、スマートスペースコンピューティング、サイバーフィジカルシステムの研究に従事。IEEE 会員。



大越 匡 (正会員)

1998年慶應義塾大学環境情報学部卒業。2000年同大学大学院政策・メディア研究科修士。2006年カーネギーメロン大学計算機科学部計算機科学科修士 (M.S. in Computer Science)。企業勤務を経て、2012年シンガポール経営大学情報システム学部研究員、2015年慶應義塾大学大学院政策・メディア研究科博士。現在、慶應義塾大学大学院政策・メディア研究科特任講師。モバイルコンピューティングシステム、ユビキタスコンピューティングシステム、分散システム、ヒューマン・コンピュータ・インタラクションに関する研究に従事。IEEE, ACM 各会員。



米澤 拓郎 (正会員)

2007年慶應義塾大学大学院政策・メディア研究科修士。2010年慶應義塾大学 Ph.D. (政策・メディア)。現在、慶應義塾大学大学院政策・メディア研究科特任講師。主に、ユビキタスコンピューティングシステム、インタラクティブシステム、センサネットワークの研究に従事。ACM 会員。



中澤 仁 (正会員)

1975年生。1998年慶應義塾大学総合政策学部卒業。2001年同大学大学院政策・メディア研究科修士課程修了。2001年同学院同研究科博士課程修了。博士 (政策・メディア)。慶應義塾大学環境情報学部准教授。ミドルウェア、システムソフトウェア、ユビキタスコンピューティング、センサネットワーク等の研究に従事。電子情報通信学会, ACM, IEEE 各会員。