

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

小淵 幹夫^{1,a)} 古川 侑紀² 西山 勇毅² 大越 匡² 米澤 拓郎² 中澤 仁¹ 高汐 一紀¹ 徳田 英幸¹

概要: 近年, スマートフォンやウェアラブルデバイスの普及により, 加速度, GPS, 歩数といった様々なセンサデータを利用できるようになった. それに伴い人間の行動を検知する研究が盛んに行なわれている. しかし, ユーザごとに定義の異なる内面状態の検知に関する研究や, 個人に最適化されたフィードバックシステムは未発達のみである. 本研究で提案する MyFactor ではユーザが日常的に使用するスマートフォンから収集されたセンサデータを用いて, ユーザが「快眠できた日」, 「疲労度の高い日」, 「忙しい日」, 「日常的な日」だと感じた日の因子を導き出す. 大学生 19 人を被験者として 40 日間にわたる評価実験を行い, 機械学習の手法を使うことでユーザの内面状態を説明する因子の検知精度を評価した.

キーワード: ライフログ, 機械学習, 行動認識

MyFactor: Factor Analysis of User's Logical Status From Lifelog Data

MIKIO OBUCHI^{1,a)} YUKI FURUKAWA² YUUKI NISHIYAMA² TADASHI OKOSHI² TAKURO YONEZAWA²
JIN NAKAZAWA¹ KAZUNORI TAKASHIO¹ HIDEYUKI TOKUDA¹

1. はじめに

近年, センサの小型化や低価格化により, 様々なセンサが搭載されたスマートフォンやウェアラブルデバイス [1–3] が広く普及している. それに伴い, 個人の行動や空間のセンシングが日常的に行われるようになり, 日々膨大な量のデータが生産されるようになった. 蓄積されたデータは健康管理や e コマースなどの分野で活用されており, 統計や機械学習の手法と組み合わせることで, データ全体の傾向の分析や未来の予測, 因子分析などへ応用されている.

また, スマートフォンやウェアラブルセンサを用いたユーザの行動認識に関する多くの研究 [4–6] が行なわれている. 特にユーザの身体的な行動や状態を検知する研究 [7–9] は数多く行なわれている. 身体的な行動や状態は, ユーザの物理的な動きや五感に深く関わっているという性質から, 多くの場合加速度やカメラ, マイクフォンといったセンサを用いて検知を行う. 一方で, より抽象的な事象, 例えばユーザの感情, 気分, 感覚といった第三者による客観的な認識が難しい事象について検知を試みる研究 [10–12] も

行われている. これらの事象の検知や認識が実現すれば, 従来のレコメンドシステムを発展させ, ユーザの気分や場の雰囲気に合わせて音楽を提案したり, 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等, その有用性は高い.

これら既存の研究における 2 つの問題に本研究は着目する. 第一は, 既存の研究では複数人の学習データから作られた総括的な一つのモデルを構築しており, 各ユーザの特性を考慮した個人に最適化されたモデルでないという問題である. Rabbi ら [9] はユーザの健康を増進する方法について「個人は不均質かつ唯一無二の存在であるため, 総括的で一般化された干渉よりも, 個人に最適化された干渉の方がユーザの要求を満足させることができる」と述べている. 一般化されたモデルでは, 学習に使われたユーザと異なる属性を持つユーザにはうまく適応できず, 検知性能が低下する恐れがある.

第二に, 既存の研究ではモデルの構築に留まっており, 導き出された因子に関する情報をユーザに還元していない. ユーザにとって重要な因子に関する情報を提供することで, QOL の向上や生活習慣の改善に繋がる行動変容を促すことができる.

本研究では, 気分や感覚といった客観的な観察が困難であるユーザの内面状態に着目する. 本研究の目的は, ユー

¹ 慶應義塾大学 環境情報学部
Faculty of Environment and Information Studies, Keio University

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

^{a)} fabius@ht.sfc.keio.ac.jp

ザの内面状態を説明する重要な因子に関する情報を導き出し、ユーザに提供することである。そこで、日常的に使用しているスマートフォンから収集されたセンサデータおよびユーザによって作成された Ground Truth を用いてモデルを構築し、因子に関する情報をユーザに還元するシステム MyFactor を提案する。MyFactor はユーザごとに学習を行うため、個人に最適化されたモデルからその個人に重要な特徴量を導き出す。MyFactor を利用すると、例えば、直接的にセンシングを行うことが難しく、かつ個人によって感じ方の異なる「疲れている」という内面状態を説明する因子に関する情報を知ることができる。そして MyFactor によって導き出された因子に注意しながら生活することによって、「疲れている」という感覚を軽減することが可能になると考えられる。

2. 関連研究

スマートフォンやウェアラブルデバイスを用いて人の行動や状態といった事象を推定し、その事象に深く寄与している因子を導き出す研究として以下があげられる。

SmartGPA [13] は、スマートフォンの使用状況からアメリカの大学生の学業成績を予測している。スマートフォンのセンサデータを用いて、「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」等の時間を推定し、それらの特徴量として用い GPA スコアとの相関を算出することで、学生がより高い成績を取るために行うべき行動と控えるべき行動を発見した。ある事柄についてスマートフォンのデータを元に寄与している因子を導き出す点は本研究と類似するが、SmartGPA は総括的で一般化されたモデルのみを構築しており、各学生個人に特化したモデルを構築していない。また、分析対象も GPA という客観的な事象である。本研究ではユーザの気分、感覚、雰囲気といった客観視することが困難な事象に焦点を充てる。

Hammer ら [10] は、本研究と同様にユーザの内面状態に着目し、ハードセンサと比べて消費電力の小さい、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“バーチャルセンサ”を用いて「isBusy」、「isStressful」、「isAlone」、「isHappy」という4つの状態を推定している。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に成功した。しかし、先程述べたように、個人は不均質であり、多様な存在であるため、各ユーザに特化したモデルを構築することで予測精度を高められる可能性がある。例えば、「自宅にいる」という状態に対して、「自宅は快適でありリラックスできる」と感じる人間もいれば、「家族の人から干渉を受けてリラックスできない」と感じる人間も存在するかもしれない。また、推定に利用した特徴量の情報をユーザに還元していない。

LiKamWa ら [11] は、「気分(mood)」と「感情(emotion)」の違いについて次のように説明している。

- 気分は感情と比べて個人が強烈に実感することは少く、持続時間が長い(数時間から数日)
- 感情が特定の事象に対する自発的な反応であるのに対し、気分は累積されたイベントに対する反応である
- 気分がより内面的なものであるのに対し、感情は他人の目から見ても明らかなものである

以上を踏まえ LiKamWa らはユーザのスマートフォンの使い方から、Circumplex Mood Model [14] に登場する「興奮」「リラックス」「退屈」「緊張」等8種類の気分(mood)を検知している。本研究で着目する内面状態は感情(emotion)よりも気分(mood)に近い。しかし、Circumplex Mood Model に存在しない「忙しい」や「疲れている」といった感覚も含まれる。

3. MyFactor

本章では、本研究での提案手法 MyFactor について述べる。MyFactor は、ユーザが自身の内面状態に関する Ground Truth をラベル付けすると、スマートフォンのセンサデータの中から、その状態の説明に深く寄与している因子に関する情報をユーザに提供するシステムである。

本研究がとりあつかう内面状態は、ユーザが主観的に感じる気分や感覚、雰囲気等、身体外部からの客観的かつ直接的な観察が困難な事象を対象とする。「歩く」や「食べる」といった、カメラや生体センサを使って身体外部から直接的に検知可能なユーザの物理行動を対象としない。また内面状態の中でも特に、数時間から数日間持続する「体調が良い」や「忙しい」といった気分や感覚に焦点を充て、数秒から数分間持続する喜びや悲しみといった感情については対象外とする。これは、気分や感覚がより内面的でユーザの根底に位置する事象であり、客観視可能にすることがより重要だからである。

ユーザの内面状態は主観的に決定されるため、直接的なセンシングが困難である。MyFactor ではユーザが日常的に使用するスマートフォン内の様々なセンサデータや利用状況に関するデータをサーバに送信・蓄積し、ユーザによって注釈された正解ラベルを元に、機械学習の手法を用いることでユーザの内面状態を推定するモデルを構築する。MyFactor はユーザ毎に学習を行うため、総括的な一般化されたモデルではなく、ユーザの主観性を考慮した、個人に最適化されたモデルを構築する。また、内面状態を説明するのに重要な因子に関する情報をユーザに還元するため、ユーザはその情報を知ることによって QOL の向上や生活習慣の改善に繋げることができる。

3.1 Ground Truth データの収集

はじめに、教師データで利用するためのセンサデータを収集するアプリケーションを実装した。対象プラットフォームは iPhone6 以降、iOS9.0 以上とした。図1に取得

表 1 iOS で収集するセンサー一覧

Table 1 A table of captured sensor data from iPhone.

加速度	緯度	経度
海拔	気圧	歩数
バッテリー残量	バッテリー充電状態	ネットワーク接続
スクリーン輝度	移動手段	移動速度




図 1 取得センサデータ表示画面

Fig. 1 A screenshot of showing captured data.




図 2 正解ラベル注釈画面

Fig. 2 A screenshot of annotating the data

中のセンサデータを表示するスクリーンショットをしめす。

アプリケーションは、表 1 に示す 12 種類のセンサデータを 10 秒に 1 度の間隔で取得しつづける。加速度センサのデータは 10Hz の周波数で取得され、10 秒間の平均を記録する。また iOS でサポートされるセンサの他に、OpenWeatherMap [15] で提供される気象データを利用する。具体的には、30 分に 1 度ユーザの現在地を同 API へ送信し、天気、気温、湿度の 3 種類のデータを取得する。センサデータは、定期的にサーバへ送信される。

iOS では、何らかの理由でアプリケーションを完全に終了してしまった場合、センサデータの取得が継続されない。データ取得の欠損を防ぐため、一定時間サーバにデータが届かなかった場合、ユーザにアプリケーションの起動を促す通知を実装した。

3.2 正解データの注釈

ユーザの内面状態を推定するために、収集されたセンサデータに正解ラベルを注釈する。本研究が対象とする気分といった内面状態は、数秒から数分持続する感情とは異なり、数時間から数日間に渡って持続する。そのため、正解ラベルの注釈作業を 1 日に 1 度行ってもらい、ラベルの対象期間も 1 日単位とした。表 2 に因子の分析を行う内面状態をしめす。

図 2 は正解ラベルの注釈を行う画面のスクリーンショットである。各項目について、リッカート尺度を用いた 5 段階（非常にそうである、そうである、どちらでもない、そうでない、非常にそうでない）で主観的な選択を求める。

表 2 因子を分析する内面状態の一覧

Table 2 A table of logical status to analyze a factor.

体調が良い日	ストレス値が高い日
疲労度が高い日	快眠できた日
忙しい日	集中できた日
気持ちがポジティブな日	日常的な日




図 3 ユーザごとの 1 日あたりの平均蓄積データ量

Fig. 3 Stored average data amount of users.

3.3 分類器の作成

ユーザの内面状態を説明する上で重要な因子を分析するために、教師あり学習のアルゴリズムによって分類器を作成する。本研究では Python 言語で書かれた scikit-learn [16] を用いる。モデルの構築は注釈が作成される度に、データが蓄積されているサーバ上で行う。

4. 予備実験

2 つの目的をもって予備実験を行った、第一に、実際にアプリケーションをユーザに利用して生活してもらい、MyFactor が問題なく動作するか確認することである。第二に、内面状態に関するラベル付けを行う作業が適切であるか見当する。

4.1 被験者

本実験の被験者として、大学生および大学院生 8 名の協力を得た。被験者は iOS 端末を主たるスマートフォンとして利用している男性 7 名および女性 1 名であり、年齢は 19 歳から 25 歳だった。

4.2 実験手順

被験者全員が日常的に使用するスマートフォンにデータ収集用アプリケーションをインストールする。毎日 23 時にスマートフォンに通知が送信され、各被験者は表 2 にしめす内面状態に関して正解ラベルの注釈を行う。これを実験期間中、13 日間繰り返した。期間終了後各被験者にラベル付け作業の感想を個別インタビュー調査した。

4.3 実験結果

1 日の蓄積データ量が 24 時間分に 1 度も届かなかったユーザは 1 人もいなかった。サーバに記録されたユーザごとの 1 日あたりの平均蓄積データ量を図 3 に示す。

8 人全員の平均蓄積データ量は 1 日あたり 20.4 時間であり、24 時間分のデータ量の 85% に相当する。

またインタビュー調査で、3 名以上のユーザから得られ

たコメントを次に記す．

- ・「毎日 8 項目回答するのはとても負担であった」
- ・「快眠に関する項目は，夜になると起床時の気分を忘れてしまうことが多かった」
- ・「ストレスに関する項目は，1 日の中でアップダウンが激しかったため，回答に困った」
- ・「集中に関する項目は，対象となる主語が設定されていないため，軸が定まらなかった」

4.4 考察

半数以上のユーザの 1 日あたりの平均蓄積データ量が 20 時間を超えていたが，全体で約 15 % のデータ量が欠損していた．主な理由として，スマートフォンのバッテリー切れや，他アプリケーションとの関連等による誤終了があげられる．そのため，対策として，データの不達時やアプリケーション誤終了時の通知を改良した．

また，ユーザのコメントを受けて，ラベル付けを行う設問項目を「快眠できた日」，「疲労度が高かった日」，「忙しかった日」，「日常的な日」の 4 つに減らした．また，「快眠できた日」のラベル付けに関しては，23 時でなく朝起床時に実施してもらうよう変更した．

5. 評価実験

本章では MyFactor の実証評価について述べる．MyFactor が提案する，ユーザの主観的な内面状態を説明する重要な因子，ユーザの実環境において実際にスマートフォンの様々なセンサデータや利用データから求められるか検証することを目的として，評価実験を行った．

5.1 評価項目

評価実験では具体的に次の項目について評価を行う．

- (1) 学習データ数と決定木のノード数および深さの評価
- (2) 6 つの機械学習アルゴリズムによる分類精度
- (3) 個人に特化したモデルと統合したモデルの分類精度

(1) では各ユーザの各設問ごとに決定木を生成し，学習データのサンプル数によってノードの数や木の深さがどのように変化するか評価を行う．決定木の生成には CART アルゴリズムを用いる．

(2) では scikit-learn に実装されている K-Nearest Neighbor (KNN)，Naive Bayes (NB)，Random Forest (RF)，Decision Tree (DT)，Logistic Regression (LR) の 6 種類のアルゴリズムでモデルを構築する．その後 leave-one-out 方式の交差検証を行い，分類精度を評価する．

(3) では個人に特化したモデルと全ユーザのデータを統合したモデルについて，leave-one-user-out 方式の交差検証を用いて分類精度の比較を行う．

5.2 被験者

本実験の被験者として，大学生 19 名の協力を得た．被

表 3 正解ラベルの前処理

Table 3 Preprocessing of user-annotated training label.

処理前のラベル	処理後のラベル
非常にそうである そうである	HIGH
どちらでもない	除外
そうでない 非常にそうでない	LOW

験者は iOS 端末を主たるスマートフォンとして利用している男性 16 名および女性 3 名であり，年齢は 19 歳から 23 歳だった．

5.3 実験手法

被験者全員が日常的に使用するスマートフォンにデータ収集用アプリケーションをインストールする．毎日朝 7 時に「快眠できた」か，23 時 30 分に「疲労度の高い日」，「忙しい日」，「日常的な日」であったか正解ラベルの注釈を行うようスマートフォンに通知を送信した．これを実験期間中，40 日間繰り返した．

5.3.1 特徴量の抽出

スマートフォンのセンサデータから教師データとして扱う 37 種の特徴量を抽出する．

表 1 のデータのうち数値データである 7 種類（気圧，海拔，移動速度，スクリーン輝度，バッテリー残量，気温，湿度）について，それぞれ 1 日における最小値，最大値，平均，標準偏差という 4 つの特徴量を計算し，合計 28 個の特徴量を算出する．また移動手段に関するデータからは，1 日における静止時間，歩行時間，ランニング時間，サイクリング時間，交通手段を利用している時間の 5 種類の特徴量を算出する．さらに，バッテリー非充電状態の時間，Wi-Fi に接続している時間，1 日の累計歩数，曜日データの特徴量として算出および利用する．

データの正確さを保つために，1 日の蓄積データ量が 80% (19.2 時間) に満たない日付のデータは学習に使用しない．

5.3.2 正解ラベルの前処理

40 日間の実験期間中，ユーザ 1 人当たりの学習データの最大サンプル数は 40 となる．学習データ数が小さいという問題が生じるため，リッカート尺度によるラベルに基づく 5 つの分類でなく，表 3 に示すように正解ラベルに対して前処理を行い，“HIGH” もしくは “LOW” のどちらかに分類する．

5.4 実験結果

実験期間中に集まった全ユーザの正解ラベルの個数は 2544 個であった．

5.4.1 生成された決定木

図 4 に，生成された決定木の例として，あるユーザに関




図 4 あるユーザが疲労度が高いと感じる日を分類する決定木
Fig. 4 A decision tree to classify the tired day for a user.




図 5 学習サンプル数と決定木の深さの遷移
Fig. 5 Relationship between sample size and depth of tree.

して「疲労度が高い日」と感じた日を分類する木（サンプル数 21，ノード数 5，深さ 2）をしめす．各ノードに存在する VALUE の左側の数字が HIGH の日数，右側が LOW の日数を表す．1 番上のノードの条件分岐に登場する特徴量は「Wi-Fi 接続時間」であり，この特徴量の値が約 13 時間以下（真）である場合，左下のノードへ行き，一方で約 13 時間より多い（偽）場合，右下のノードへ行くという構図になっている．この決定木を言語化するとすれば，このユーザは Wi-Fi 接続時間が 13.375 時間以下であり，かつ気圧の最低値が 97.0615kPa より大きい日は疲労度が高い日だと感じるという意味になる．

4 つの各設問における学習サンプル数，ノード数，木の深さに関して，平均と標準偏差を表 4 にしめす．サンプル数，ノード数，木の深さは設問ごとに大きな差は無かった．木の深さは「忙しい日」が 2.9 段と最も小さく，「日常的である日」が最も大きい 3.5 段であった．

5.4.2 アルゴリズムごとの分類精度

各設問ごとに 6 つのアルゴリズムを用いてモデルを構築し，leave-one-out 方式交差検証による平均分類精度を表 5 にしめす．最も高精度で分類できたのは，Random Forest を用いてユーザの「忙しい日」を推定するモデルであった．

5.4.3 個人モデルと統合モデルの分類精度

表 6 に，Random Forest を用いた場合の，個人毎に作成

表 4 各設問における学習データ数と決定木のノード数および深さ
Table 4 A table of sample size, nodes and depth of trees.

	快眠できた	疲労度が高い	忙しい	日常的である
サンプル数 (平均)	23.3	23.4	24.4	25.9
サンプル数 (標準偏差)	8.0	7.6	7.7	6.5
ノード数 (平均)	8.6	8.6	8.3	9.6
ノード数 (標準偏差)	2.8	4.5	3.6	3.7
木の深さ (平均)	3.1	3.3	2.9	3.5
木の深さ (標準偏差)	1.1	1.6	1.0	1.4

表 5 6 つのアルゴリズムによる分類精度
Table 5 Predictive accuracy by 6 algorithms.

	KNN	SVM	RF	NB	DT	LR
快眠できた日	0.591	0.539	0.594	0.569	0.612	0.599
疲労度の高い日	0.660	0.601	0.639	0.614	0.632	0.653
忙しい日	0.677	0.582	0.695	0.6	0.588	0.62
日常的な日	0.585	0.524	0.611	0.572	0.578	0.607

表 6 個人モデルと統合モデルの分類精度
Table 6 Accuracy of personalized model and generic model.

	個人モデル	統合モデル
快眠できた日	0.594	0.602
疲労度の高い日	0.639	0.592
忙しい日	0.695	0.62
日常的な日	0.611	0.591

する「個人モデル」と全ユーザのデータを統合して作る「統合モデル」の分類精度を比較する．「快眠できた日」以外の 3 つの項目では，統合モデルよりも個人モデルの方が高い精度で分類ができた．

5.5 考察

決定木はアルゴリズムの内部で特徴選択を行っているため，学習に使われている 37 個の特徴量すべてが決定木に登場されないのに加え，条件分岐に沿って進んでいけば結果にたどり着くため，可読性が高いアルゴリズムと言える．図 4 の決定木のユーザに実際に決定木を見せ，「貴方は Wi-Fi 接続時間が約 13 時間より多い日，疲労度が高くないと感じる」と説明した所「Wi-Fi がある自宅に長くいる日は，疲労を確かに感じにくい」というコメントを得た．

単純な決定木ではあるが，MyFactor が提案する手法でユーザの内面状態を推定することが可能であると考えられる．本実験で生成された木のノード数は約 9 個，深さは約 3 であり，人間がモデルを把握することが可能な大きさであると言える．しかし，図 5 にしめすように，学習データが増加すると共に，木のノード数や深さが増え，複雑になっていくという問題に直面する．また「気温の分散」や「気圧の分散」といった特徴量はユーザにとって認知が難しい特徴量であるため，ユーザに因子を提供する際は，ユーザの理解しやすい特徴量を用いることが重要だと考えられる．

6 種類のアルゴリズムを用いて行った個人モデルの分類

精度では、顕著な差はなかったが Random Forest が最も高精度で分類を行った。交差検証による精度が約 0.6 から 0.7 の範囲内であるため、汎化能力は高いとはいえない。精度を改善するために、学習データを増やすと共に、より有益な特徴量を抽出する必要がある。

最も分類精度の高かった Random Forest を用いて構築した個人モデルと統合モデルでは、表 6 にしめす通り、大きな差は見られなかったが 3 つの内面状態において個人モデルの方が高い精度を記録した。この結果は、ユーザの内面状態を推定するには、学習データ数が圧倒的に多い統合モデルを用いるよりも、ユーザ個人に特化したモデルの方が高精度な分類器になるという可能性を支持するといえる。

6. 今後の課題

今後の課題として第一に、分類器の精度の課題があげられる。学習データ数を増やした場合の精度の変化を継続評価すると共に、内面状態を推定するのに有効な特徴量の検討や選択を引き続き行う。第二に、内面状態を分類精度における個人モデルと統合モデルの継続的な比較検討があげられる。学習データのサンプル数と比較しながら評価を継続していく。

第三に、ユーザへの重要因子情報の還元方法の検討があげられる。データ増加により学習させたモデルが巨大になった場合、また Random Forest といった単純な決定木では表現できないアルゴリズムにおける重要な因子に関する情報をどのようにユーザにとって有益な方法で還元するか、検討し手法を研究開発する。

7. おわりに

本研究では、ユーザの主観的な事象である内面状態を説明する重要な因子に関する情報をユーザに提供するシステム「MyFactor」を提案した。スマートフォンのセンサデータを収集するアプリケーションの実装を行い、大学生 19 名による 40 日間の実証実験を通じて、ユーザの作成した注釈を元に「快眠できた日」、「疲労度の高い日」、「忙しい日」、「日常的な日」の 4 つの内面状態に関する決定木を生成した。また、6 つの機械学習アルゴリズムによる分類精度の評価を行い、Random Forest が最も高精度であった。加えて、個人に特化したモデルとユーザ全体で学習を行ったモデルの分類精度を比較し、「疲労度の高い日」、「忙しい日」、「日常的な日」に関して個人に特化したモデルの方が高精度で分類を行うことができる可能性をしめした。

参考文献

- [1] Fitbit Inc. Fitbit. <http://www.fitbit.com/jp>.
- [2] Jawbone Inc. Jawbone. <https://jawbone.com/>.
- [3] Apple Inc. Apple watch. <http://www.apple.com/watch/>.
- [4] Vijay Srinivasan, Saeed Moghaddam, Abhishek Mukherji, Kiran K. Rachuri, Chenren Xu, and Emmanuel Munguia Tapia. Mobileminer: Mining your frequent patterns on your phone. In *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '14, pp. 389–400, New York, NY, USA, 2014. ACM.
- [5] Jun-Ki Min, Afsaneh Doryab, Jason Wiese, Shahriyar Amini, John Zimmerman, and Jason I. Hong. Toss 'n' turn: Smartphone as sleep and sleep quality detector. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, CHI '14, pp. 477–486, New York, NY, USA, 2014. ACM.
- [6] Eunju Kim, S. Helal, and D. Cook. Human activity recognition and pattern discovery. *Pervasive Computing, IEEE*, Vol. 9, No. 1, pp. 48–53, Jan 2010.
- [7] Ling Bao and Stephen S. Intille. *Pervasive Computing: Second International Conference, PERVASIVE 2004, Linz/Vienna, Austria, April 21–23, 2004. Proceedings*, chapter Activity Recognition from User-Annotated Acceleration Data, pp. 1–17. Springer Berlin Heidelberg, Berlin, Heidelberg, 2004.
- [8] 古川侑紀, 西山勇毅, 大越匡, 中澤仁, 高汐一紀, 徳田英幸. 加速度センサのみを用いた移動手段判定アルゴリズムの評価. 研究報告モバイルコンピューティングとユビキタス通信 (MBL), Vol. 2014, No. 43, pp. 1–7, mar 2014.
- [9] Mashfiqui Rabbi, Min Hane Aung, Mi Zhang, and Tanzeem Choudhury. Mybehavior: Automatic personalized health feedback from user behaviors and preferences using smartphones. In *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '15, pp. 707–718, New York, NY, USA, 2015. ACM.
- [10] Jon C. Hammer and Tingxin Yan. Exploiting usage statistics for energy-efficient logical status inference on mobile phones. In *Proceedings of the 2014 ACM International Symposium on Wearable Computers*, ISWC '14, pp. 35–42, New York, NY, USA, 2014. ACM.
- [11] Robert LiKamWa, Yunxin Liu, Nicholas D. Lane, and Lin Zhong. Moodscope: Building a mood sensor from smartphone usage patterns. In *Proceeding of the 11th Annual International Conference on Mobile Systems, Applications, and Services*, MobiSys '13, pp. 389–402, New York, NY, USA, 2013. ACM.
- [12] 山本純平, 川添瑞木, 中澤仁, 高汐一紀, 徳田英幸. Molmod: 生体情報を用いた雰囲気取得手法の構築 (ユビキタス・センサネットワークの要素技術, コンテキストの抽出, スマートスペース, ユビキタス生活支援, 一般). 電子情報通信学会技術研究報告. USN, ユビキタス・センサネットワーク, Vol. 109, No. 131, pp. 63–68, jul 2009.
- [13] Rui Wang, Gabriella Harari, Peilin Hao, Xia Zhou, and Andrew T. Campbell. Smartgpa: How smartphones can assess and predict academic performance of college students. In *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, UbiComp '15, pp. 295–306, New York, NY, USA, 2015. ACM.
- [14] J.A. Russell. A circumplex model of affect. *Journal of personality and social psychology*, Vol. 39, No. 6, pp. 1161–1178, 1980.
- [15] OpenWeatherMap Inc. Openweathermap. <http://openweathermap.org/>.
- [16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and E. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Res.*, Vol. 12, pp. 2825–2830, 2011.