

推薦論文

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

濱谷 尚志^{1,a)} 落合 桂一¹ 山本 直樹¹ 深澤 佑介¹ 木本 勝敏¹
上西 康平² 太田 順² 寺澤 悠理³ 沖村 宰³ 前田 貴記³

受付日 2020年6月23日, 採録日 2021年1月12日

概要: 近年わが国では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ている. スマートフォンはユーザが日々持ち歩き, 使われるものであるため, ユーザの心理状態を反映することが期待できる. 本研究では, ユーザのスマートフォン利用や持ち歩きによって収集されるログデータについて, 時間的観点, 空間的観点の両観点からログを分析し, 利用者のストレスを推定する手法を提案する. その結果, 21人のユーザにおいて, 推定精度 88.7%で利用者のストレスの高低度合いを推定可能であり, 時間だけでなく空間的観点でログを集計することが有効であることを確認した.

キーワード: スマートフォン, ストレス, メンタルヘルスケア, 滞留点抽出

Stress Estimation Based on Spatiotemporal Analysis of Smartphone Usage and Sensor Data

TAKASHI HAMATANI^{1,a)} KEIICHI OCHIAI¹ NAOKI YAMAMOTO¹ YUSUKE FUKAZAWA¹
MASATOSHI KIMOTO¹ KOHEI KAMINISHI² JUN OTA²
YURI TERASAWA³ TSUKASA OKIMURA³ TAKAKI MAEDA³

Received: June 23, 2020, Accepted: January 12, 2021

Abstract: With the spread of smartphones worldwide, there have been growing interests in healthcare using smartphones recently. Smartphones are expected to understand psychological context of those owners because they are usually with owners. In this study, we propose a method to estimate human stress using usage and sensor logs in a smartphone with consideration of spatiotemporal context. To extract spatial contexts of users, the proposed method presents an algorithm of stay detection in most important points that play the role of home and workplace. Our evaluation revealed that the proposed spatial features were effective to extract important contexts related to human stress and successfully combined with the chronological features to improve stress estimation with up to 88.7% accuracy.

Keywords: smartphone, stress, mental healthcare, stay point analysis

1. はじめに

世界保健機関 (WHO) の調査によると, 世界中で 3 億人もの人がメンタルヘルスの不調をかかえており, メン

タルヘルスの不調による労働生産性の低下にともなう経済損失は 1 兆ドルにのぼるとも試算されている [1]. メンタルヘルスの不調に至る原因としてよく知られているのがストレスであり, メンタルヘルスの不調を防ぐためには, 過度なストレスを避け, 自身が受けているストレスを自覚し予防に努めることが重要である [2], [3].

¹ 株式会社 NTT ドコモ
NTT DOCOMO, INC., Chiyoda, Tokyo 100-6150, Japan
² 東京大学
The University of Tokyo, Bunkyo, Tokyo 113-8654, Japan
³ 慶應義塾大学
Keio University, Shinjuku, Tokyo 160-0016, Japan
a) takashi.hamatani.rt@nttdocomo.com

本論文の内容は 2019 年 11 月の第 93 回 MBL・第 79 回 ITS 合同研究発表会にて報告され, モバイルコンピューティングとパーベイシブシステム研究会主催により情報処理学会論文誌ジャーナルへの掲載が推薦された論文である.

一方、昨今スマートフォンの普及率は世界的に増大しており、スマートフォンを活用したエージェントサービスやヘルスケア技術への関心が高まってきている。スマートフォンは複数のセンサを搭載していることから、歩数や移動経路の記録など、ヘルスケアへの応用がなされている。また、ユーザが多数のアプリや機能を使うことで様々なログが取得可能であり、ユーザの趣味趣向などを推定することが可能になりつつある [4]。

このような背景をふまえ、これまで本研究チームでは、スマートフォンの使い方を決まった時間単位で集計することにより、スマートフォンの持ち歩き方、使い方に関するログデータの特徴量化し、ウェアラブル心電計により取得したストレスの指標と照らし合わせることでユーザのストレスを推定する手法の研究を行ってきた。この手法により、多くのデータに基づいて学習した時間帯ごとのスマートフォンの使い方とユーザのストレスの関係に基づいて、ストレスを推定することができる。一方で、決まった時間単位でのスマートフォンログ集計では、ログが発生した空間的なコンテキストを考慮できない可能性がある。たとえば、同じ時間に電話をしている場合においても、自宅で電話をするのと職場で電話をするのでは、電話の目的や電話によって生じる心理的な影響に差異があると考えられる。従来の研究でも、ユーザのメンタルヘルスの状態とユーザの位置情報に着目した研究がなされており、位置情報はユーザの心理状態を認識するために有用であると考えられている [5], [6]。しかしながら、位置情報はユーザにとってプライバシーに関わる情報でもあるため、必ずしも取得できるとは限らないという課題がある。

そこで本研究では、ユーザが訪れる場所によって、スマートフォンの利用ログの意味合いが異なりうるという想定のもと、ユーザの滞留地点に着目し、空間的にスマートフォン利用ログを分析することで、著者らがこれまでに提案した時間的観点に基づいたストレス推定の精度向上を図る。さらに、空間的なログ分析において、ユーザのプライバシー配慮への必要性に鑑み、空間的にログを集計するための滞留地点の検出において、位置情報を用いる方法だけでなく、位置情報を周辺 WiFi アクセスポイント情報で代替する方式を提案する。空間的なログ分析における課題として、ある地点とユーザがその地点を訪れるコンテキストが必ずしも 1 対 1 で対応しない可能性がある。たとえば、駅は通勤通学のために利用されることもあれば、余暇の時間の待ち合わせに利用されることもあり、駅にいる時間のログデータから行動に関する特徴量を生成したとしても、ストレスと特徴量の関係がユーザごとに異なる可能性がある。したがって本研究では多くのユーザで共通の目的で滞在する地点であると考えられる、寝食を行う地点（自宅など）、および日中活動を行う地点（職場など）の 2 地点を重要な滞在地点と位置づけ、これらの 2 地点への滞在時に

おけるスマートフォンの持ち歩き方、使い方に関するログデータの特徴量化することで空間的コンテキストをストレス推定に活用する。

実際に 21 人の合計 200 日以上のログデータにおいて、位置情報に基づきユーザの訪れた点を時空間的にクラスタリングしたうえで、寝食を行う地点と日中主に活動する地点、およびそれらに類する地点と、その他の滞在地点ごとにログデータを集計することでユーザの行動を空間的観点で特徴量化した結果、従来の時間的観点の特徴量のみを用いる場合と比較して、ストレスの推定精度が向上することを確認した。従来研究、ならびに著者らの先行研究に対する本研究の貢献は次のとおりである。

- ユーザの滞留位置ごとにスマートフォンの各種ログを特徴量化し、時間ごとに生成した特徴量と組み合わせることでユーザのストレスの高低推定精度 88.7%を確認し、時空間的コンテキストをふまえた特徴量の有効性を確認した。
- プライバシーへの配慮のため、位置情報の代替として周辺 WiFi 情報を用いて重要な滞留点を抽出する方式を実装し、位置情報および WiFi 情報をそれぞれストレス推定に用いる場合の精度の比較を行った結果、同等の精度でストレスを推定できることを確認した。

2. 関連研究

2.1 スマートフォンを用いた人のストレス推定

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できる。こういったスマートフォンの特徴に着目し、これらのセンサから得られる情報を用いることでユーザのストレスを推定する研究が行われている [7]。これらの研究では、スマートフォンの持ち歩きや利用傾向からユーザの感じているストレスを推定できる可能性を示している。また、Canzian らの研究 [8] では、位置情報を用いて得られたユーザの移動軌跡を用いてユーザの抑うつ状態を推定する手法を提案している。また、Ware らは上記の研究を発展させ、大学生を対象に、大学の IT サービスへの接続情報（各 WiFi アクセスポイントの MAC アドレス、接続デバイスの MAC アドレス、接続開始時間および接続時間）を用いることで、位置情報を用いず、アクセスポイント単位での位置情報を用いて抑うつ状態の推定を行っている [9]。以上の研究のように、スマートフォンから得られる情報を活用したユーザの心理状態推定の取り組みが数多く行われてきている。さらに、後者の研究のように、人が滞在する場所と人の心理状態の関係性に着目した研究も数多く行われており [5], [6]、本研究においても、滞在地点の種別ごとにスマートフォンログを分析することで、ストレスの推定精度の向上を図る。

2.2 本研究チームのこれまでの取り組み

上述の研究など、従来のストレスの推定に関する研究では、PHQ-9 [10] (生活に関する9個の質問) などのアンケートを用いてユーザの抑うつ度を計る方法が主流であった。こういったアンケートを用いた方法では、ユーザの生活の中で、定められたアンケートに回答してもらうだけでユーザの心理状態に関する正解データを得られるという利点がある。一方で、回答結果がユーザの主観に依存するため、利用者が気づいていない潜在的な心理状態の抽出や、連続的に正解データを取得することが困難である。

そこで、筆者らの研究チームではウェアラブル心電計を用いて取得可能であり、ストレス状態と関連する指標として知られる LF/HF [11] を正解データとし、スマートフォンより得られるログと組み合わせて推定モデルを構築することにより、客観的なストレスの推定手法の研究を行ってきた。スマートフォンログを用いたストレスの推定可能性検討のため、11種のスマートフォンログ(加速度、角速度、気圧、位置情報、充電、イヤホンの接続、画面のオンオフ、アプリの起動ログ、バッテリー、Google Activity Recognition、ストレージ容量)について、合計128次元の特徴量を実装し、推定モデルを構築することで71.1%の精度でストレスを推定可能であることを示した [12]。さらに、ストレスの推定精度の向上のためストレスと相互作用があると考えられるユーザの注意機能に着目し、ストレスと注意機能の相互作用を考慮したストレス推定手法を提案し、実際に相互作用の考慮によりストレス推定精度が向上することを確認した [13]。

本研究では、従来の時間的なコンテキストを考慮した特徴量に加え、空間的なコンテキストを考慮した特徴量の生成によりストレス推定精度の向上を図る。これまでに、重要な位置でのSMSや電話の利用を特徴量として利用する研究はなされているが [14]、本研究ではアプリケーションの利用以外にも人の動きや環境などが空間的なコンテキストと関連していると考え、重要な地点におけるスマートフォ

ンログを網羅的に特徴量化し、ストレス推定への効果検証を行う。

3. ストレス推定手法

本研究では、著者らの先行研究 [13] で提案したストレス推定手法と同様の枠組みを用いてストレスの推定を行う。この際に、以後の4章で提案する空間的なスマートフォンログ集計に基づく新規特徴量を追加し、場所ごとのスマートフォン利用がユーザの心理状態と関連するかを明らかにすることが本研究の狙いである。本章ではストレス推定手法の概要を述べるが、詳細については先行研究 [13] を参照されたい。

3.1 概要

ストレス推定の流れを図1に示す。まず、スマートフォンより取得可能なログを収集し、ユーザのスマートフォン所持や利用の特徴を表す特徴量を生成する。生成した特徴量は、ストレス状態の正解データとなる LF/HF のデータと組み合わせ、教師あり機械学習により特徴量を入力としたストレス推定モデルを構築する。モデル構築後、モデルの推定精度の評価を行う場合は、生成した特徴量をモデルに与えることで得られる推定結果と、正解データを比較することにより実施する。

3.2 スマートフォンログの収集

近年、日本で利用されているスマートフォンのOSのシェアはAndroid OSおよびiOSが主である。両者を比較すると、Android OSではアプリ開発者が端末のアプリケーション利用履歴にアクセスできる一方で、iOSではアプリケーション利用履歴へのアクセスが制限されており、Android OSの方がより多くのログを取得可能である。したがって本研究では、スマートフォンを用いたストレスの推定可能性の検討のためAndroid OSを対象とし表1に示すログを取得する。スマートフォンの状態に関するログ




図1 スマートフォンログを用いたストレス推定モデル構築手法の概要

Fig. 1 Overview of model training for psychological stress estimation using smartphone log.

表 1 収集するスマートフォンログ

Table 1 Smartphone log collected in our study.

ログ種別	取得頻度
加速度 (3 軸), 角速度 (3 軸), 端末傾き (3 軸)	1 秒ごと
気圧, 周辺照度, バッテリ残量, 接続先 WiFi アクセスポイント情報, 周辺 WiFi アクセスポイント情報, Google Activity Recognition 結果, 位置情報	5 分ごと
ストレージ空き容量, 曜日情報	1 日 1 回
画面のオン・オフ, アプリの起動・終了, イヤホンジャックへの接続, 充電器への接続	イベント発生時

(センサ類や位置情報など)の取得間隔は小さければ小さいほどより詳細な情報が得られるが, 取得データ数の増加にともないバッテリー消費量やログファイルのサイズが増大するため, トレードオフの関係になる. 本研究では上記の関係に鑑み, 表 1 に定める頻度でログを取得する.

3.3 特徴量の生成

上述のスマートフォンログでは, 取得タイミングごとの値が記録されているが, ログそのものは膨大な数値の羅列であるため, ログそのものを用いてストレスの状態を推定することは困難である. 本研究ではユーザがストレスを受けているときに表れる行動をスマートフォンログから検出することを目的とし, 以下の 4 種類の観点でログから特徴量を生成する. (1) 人やスマートフォンの動きに関する特徴量 – ストレスを受けることによりユーザやスマートフォンの動きが影響を受ける. (2) 周辺環境に関する特徴量 – 周辺環境の変化がストレスに影響を与え, 環境の変化でストレスによる人の行動を解釈する. (3) 人の移動に関する特徴量 – ストレスの状態が人の移動方法や訪れる場所に影響を与え, 訪れる場所により人のストレス状態が変化する. (4) スマートフォンの使い方に関する特徴量 – ストレスの状態によりスマートフォンを使う目的や使い方が変化する.

著者らのこれまで研究では, 上記の特徴量を 1 時間ごと, 6 時間ごとおよび 24 時間ごとに生成し, ストレス推定のための特徴量としていた. 一方, 本研究では上記特徴量を決まった時間単位ではなく, ユーザが訪れた場所ごとに集計することで空間的な観点からスマートフォンログを集計しストレス推定に活用する. すなわち, 生成する特徴量の種類自体はこれまでの手法と同様であるが, 決まった時間単位ではなくある地点に滞在した時間帯のログを対象として特徴量を生成する. 生成する特徴量の詳細を表 2 に示す. 各特徴量の詳細な生成方法は先行研究 [13] を参照されたい.

なお, 図 1 に示すとおり, 本研究では推定モデル構築のための正解データとなるストレス指標について, 今回のデータ収集対象者の勤務時間帯に含まれる 13 時から 16 時の LF/HF の値を用いている. これに対し, 提案手法では

表 2 生成する特徴量

Table 2 Behavioral features extracted in our method.

種別	特徴量
ユーザやスマートフォンの動き	加速度・角速度・端末傾きにおける平均値・標準偏差・最大値・最小値・最大値と最小値の差・ノルム・相関係数, Google Activity Recognition における各 Activity クラスの割合
周辺環境	気圧と照度の平均値・標準偏差・最大値・最小値・最大値と最小値の差, 接続および観測した WiFi アクセスポイントの数
ユーザの移動	緯度・経度・高度 (初期位置を基準とする相対座標系) の最大値・最小値・最大値と最小値の差, 先行研究 [8] で用いられた特徴量 (移動距離, 移動距離の分散, 重要地点数など)
スマートフォンの使い方	画面オン・オフの回数・オンの時間平均, 偏差, 最大値・最小値, 各カテゴリごとのアプリの起動回数・起動時間の平均, 偏差, 最大値・最小値, アプリ (各カテゴリ) 起動, および画面オンにおける 1 時間ごとの確率分布の Bhattacharyya 係数 [15] (対前日比, 対前週比, 対ユーザ平均比)

当日 0 時から翌日 0 時の 24 時間のスマートフォンのログから上述の 4 観点の特徴量を抽出しており, 行動特徴量とストレス指標の集計を行う時間帯が異なる. 勤務時間帯以外のスマートフォンのログデータを用いるべき理由としては, 勤務時間中にスマートフォンを利用する場合とプライベートな時間でのスマートフォンの利用傾向が異なることがあげられる. 具体的には, 勤務時間帯で受けたストレスの程度により, 勤務時間終了後のプライベートな時間でのユーザの移動や, スマートフォンを利用した活動の傾向が異なり, また, 勤務開始前のプライベートな時間での行動が勤務時間中に受けるストレスと関連する可能性がある. したがって, 提案手法では, 勤務時間帯だけでなく勤務時間の前後のユーザの行動を分析することで, より高精度にストレスを推定できることを期待し, 0 時から翌日 0 時までの 24 時間のデータを利用しユーザの行動特徴量の抽出を行った.

3.4 教師データの作成

2.2 節で述べたとおり, 本研究ではユーザの客観的なストレスの推定のため, 胸部心電計を用いて計測した心電波形より得られる LF/HF [11] をストレスの正解データとして収集する. LF および HF はそれぞれ心電波形の低周波成分と高周波成分を表す. LF/HF は交感神経と副交感神経の活性度のバランスを示すことが知られており, ユーザがストレス状態にあると LF/HF の値が大きくなることが知られている [11]. 本研究では大局的なユーザのストレスを推定することを目的としており, 心電計より得られた 5 分ごとの心電波形に対し以下の式 (1) および (2) を適用す

ることである1日の13時から16時までのLF/HFの値の代表値 ($LF/HF_{u,d}$) を求める。LF/HFの絶対値は人によって異なりうる値であるため、ユーザが受けているストレスが高いか否かの判断のため、式(3)により各ユーザにおけるLF/HFの平均値 $E(LF/HF_u)$ を求め、式(4)により、ある1日のLF/HFの値がユーザの平均値より高いかどうかに着目する。この方法により、ユーザの1日のLF/HFの代表値を1(ストレスが高い)または0(ストレスが低い)に変換し、後述の推定モデル構築における教師データとする。

$$LF/HF_{u,t,d} = \frac{\int_{0.04}^{0.15} f_{u,t,d}(\lambda)d\lambda}{\int_{0.15}^{0.40} f_{u,t,d}(\lambda)d\lambda} \quad (1)$$

$$LF/HF_{u,d} = \frac{1}{|W|} \sum_{t \in W} LF/HF_{u,t,d} \quad (2)$$

$$E(LF/HF_u) = \frac{1}{|D_u|} \sum_{d \in D_u} LF/HF_{u,d} \quad (3)$$

$$x_{u,d} = \begin{cases} 1 & (LF/HF_{u,d} > E(LF/HF_u)) \\ 0 & (\text{otherwise}) \end{cases} \quad (4)$$

式(1)において、 u は各ユーザを示す符号、 t は5分単位で定めた時間窓、 d は日付、 $f(\lambda)$ は心拍周期(R-R Interval)を高速フーリエ変換でスペクトル分解して得られた周波数成分 λ ごとのパワースペクトルを表す。また、式(2)において W は時間 $[t1, t2]$ に含まれる時間窓を表しており、提案手法では $t1$ として13時、 $t2$ として16時を適用した。式(3)はユーザごとの実験期間全体のLF/HFの平均値を表しており、式(4)によりストレスの高低のラベルへと変換する基準として用いる。ここで集合 D_u はユーザ u において13時から16時の時間帯でLF/HFを計算できたすべての日を示す。式(4)では、 $x_{u,d}$ はある1日のストレスがユーザ u の平均値 $E(LF/HF_u)$ より高いかどうかを表しており、1が高ストレス、0が低ストレスであることを示している。本研究では、以上の定式化により、ある1日におけるLF/HFの代表値 $LF/HF_{u,d}$ を計算したうえで、ユーザの平均値 $E(LF/HF_u)$ との大小比較に基づき、1または0で表されるストレス状態の高低のラベル $x_{u,d}$ へと変換する。

なお、本研究では日勤帯の定形勤務を行う労働者を対象としてデータ収集を行ったこと、昼の休憩時間に行われる食事や運動は心拍変動(LF/HF)へと影響を与えうること[16],[17]、ならびに実際に心電波データを多くのユーザで共通して取得できていたことから、ストレスの指標としてLF/HFを集計する時間帯として $t1$ として13時、 $t2$ として16時を定めた。

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より得られた特徴量を説明変数、3.4節で作成した教師データを目的変数とす

る教師あり機械学習により、ストレス推定モデルを構築する。機械学習のアルゴリズムは複数手法の比較の結果に基づき extreme gradient boosting (XGBoost) [18] を用いる。学習において説明変数の次元が膨大となるが、膨大な次元数での学習は次元の呪いにより学習が困難になるため、XGBoostでのモデル学習時に得られる各特徴量の重要度の値に基づき重要な特徴量のみを選択することで次元数を削減する。また、機械学習モデルの訓練において陽性と陰性のデータ数に偏りが生じる場合があり、偏った教師データで学習することは過学習の原因となるため、SMOTE (synthetic minority over-sampling technique) [19] を用いてオーバーサンプリング (oversampling) を行い、教師データにおける陽性と陰性の割合を均一化した。

4. 提案手法：重要滞留点におけるスマートフォンログの特徴量化

4.1 提案手法の概要

本研究では、ユーザの保持するスマートフォンログを空間的観点で分析することにより、空間的なコンテキストをふまえたストレス推定を行う。ユーザの位置情報を表すログを分析することで、ユーザがどういった場所に滞留していたかを解釈することが可能である。ユーザのストレスと滞留する地点の関係の分析のためには、単なる物理的な滞留位置(緯度、経度など)ではなく、滞留地点の意味(自宅や職場などの論理的な位置)を解釈することが重要である。すなわち、論理的な位置情報を解釈することで、異なるユーザの滞留点情報の比較が可能になる。

ユーザが滞在する地点の意味として、たとえば自宅、職場、買い物のための場所、娯楽のための場所など、多岐にわたると考えられる。物理的な位置情報だけでは滞在地点の意味を判別することは困難であるが、地図情報や施設の情報と組み合わせることで、ユーザが滞留した地点の属性(住宅街、オフィス街、商業施設など)を判断することができる。一方で、同じ商業施設を訪れる場合でも、仕事として訪れる場合と買い物のために訪れる場合など、地点に対し複数の意味が対応する可能性があり、単に施設情報を利用するだけでは滞留地点の意味を解釈することが困難である場合がある。

したがって、本研究では同様の意味を持つ滞留点には時間的に同様の傾向で滞在するという仮説を設ける。たとえば、商業施設を仕事として訪れる場合、日中の長い時間にわたって商業施設に滞在することが考えられるが、この滞在傾向はオフィス街で働く社員がオフィス街を訪れるときの滞在時間の傾向と類似すると考えられる。同様に、ユーザによって自宅の物理的な座標は異なるものの、夜間就寝のため同じ座標にまとまった時間滞在する傾向があると考えられるため、夜間にまとまって滞在している点を自宅の意味を持つ滞留点であると考えられることができる。そこ




図 2 位置情報を用いたユーザーの重要地点抽出アルゴリズム

Fig. 2 Stay-point extraction algorithm using locational information.




図 3 WiFi 情報を用いたユーザーの重要地点抽出アルゴリズム

Fig. 3 Stay-point extraction algorithm using ambient WiFi access point history.

で本研究では、ライフスタイルが異なるユーザーにおいても、特に滞在時間の分布傾向が類似するであろう、自宅（主に寝食を行う場所）および職場（日中主に活動を行う場所）の2種類の場所に着目し、これらの地点におけるスマートフォンログより特徴量を生成することで、空間的コンテキストを考慮したストレス推定を行う。

4.2 重要滞留点抽出方式

提案手法では図 2 または図 3 に示すアルゴリズムを用いてユーザーにとって重要な滞留点を抽出する。上述のとおり、本研究では寝食および日中の活動を行う2種類の地点が多くユーザーにおいて共通して重要な地点であると想定し、第一重要地点（主に寝食をする場所）、および第二重要地点（主に活動をする場所）の2地点を推定し、それらの地点におけるスマートフォンログより特徴量を生成する。重要地点の数を限定することで、数多くのユーザーから共通して特徴量を生成することができるため、異なるユーザーを比較する推定モデルを構築可能であると考えられる。さらに、第一重要地点および第二重要地点に滞在していない時間帯におけるログからも特徴量を生成する。以上の3種類の論理的滞留位置を位置情報または周辺 WiFi アクセスポイント情報を用いて抽出する方式を提案する。

位置情報は主に GPS を利用するため、緯度経度単位での位置情報の取得が可能であり高精度な位置情報が得られる。しかしながら、継続的な取得においてはバッテリー消費量の増大が問題となる。一方で、周辺 WiFi アクセスポイント情報は WiFi 接続のために受動的に収集可能な情報のため、WiFi 接続を利用する多くのスマートフォンにおいて追加のバッテリー消費を要しないという利点がある。その一方で、得られる情報はアクセスポイントの名称や MAC アドレスであるため、物理的な位置情報を得ることができ

ないという欠点がある。以上の2種類のログは、それぞれユーザーの論理的な位置を推定できる可能性があるが、性質が異なるため、本研究では2種類のそれぞれを用いたユーザーの重要滞留点での滞在の抽出方式を検討する。

4.2.1 位置情報を用いた重要滞留点抽出

位置情報は緯度経度の系列であるため、ユーザーの行動理解に用いる場合には地図情報や施設情報などと組み合わせる必要があり解釈が困難である。そのため、ユーザーが類似する座標で滞留していた場合に滞留点としてまとめる処理を行い解釈を容易にする。本研究では Nishida らの時空間クラスタリング手法 [20] を利用することにより、地理的に近くかつまとまった時間滞在している地点を滞留点として抽出する。

クラスタリングの結果得られた滞留点の系列からユーザーの第一重要地点および第二重要地点を推定するため、提案手法では多くのユーザーが就寝していると考えられる午前3時にユーザーが最も滞在している滞留点を第一重要地点と推定する。また、就寝以外、すなわち主な活動時間帯においてユーザーが長時間滞在している地点をユーザーにとって重要な活動地点であると見なし、第一重要地点を除いたうえで最も滞在時間の長い滞留点を第二重要地点と定める。以上の方法を 5.1 節で述べるデータセットに適用し得られた、全ユーザーにおける第一重要地点および第二重要地点への滞在時間帯の確率密度分布を図 4 に示す。以上の方法により、第一重要地点および第二重要地点を表す代表点をそれぞれ求める。

また、本研究では 5.1 節で述べるデータセットを用いてモデルの構築や評価を行うが、このデータセットは複数の勤務地を有する会社員を対象に収集したものである。したがって、各ユーザーにとっての第二重要地点は主に勤務する地点を表すが、勤務地は1つとは限らないため、複数の勤




図 4 第一重要地点および第二重要地点への滞在時間帯の確率密度分布 (位置情報利用)

Fig. 4 Probability distribution of stay occurrence at the first and second important locations (based on location information).

務地をまとめて第二重要地点群として処理することが望ましい。同様に、第一重要地点として、自宅や長期出張の宿泊先など、寝食を行う地点が複数存在する可能性がある。

以上のように、第一 (第二) 重要地点の代表点のほかに、同様の役割を持った滞留点をまとめて第一 (第二) 重要地点として扱えるようにする必要がある。滞留点の役割が第一 (第二) 重要地点の代表点と同様かどうかを判定するために、同じ目的で滞在する点と同様の時間的傾向で滞するという想定のもと、滞在時間帯の確率密度分布の類似度が高い滞留点を同一目的の滞留点として扱う。具体的には、各重要地点に対し、1 時間ごとの滞在確率分布の比較における Bhattacharyya 係数 [15] が 0.9 以上の滞留点を同一の役割を持つ滞留点と見なす。さらに、その滞留点が重要であるかどうかの判断のため、滞在確率分布の類似度が高いだけでなく滞在時間の長さにも注目する。具体的には、第一 (第二) 重要地点の代表点の滞在時間に対して、滞在時間が 30% 以上である滞留点を重要な滞留点であると判断する。以上の 2 種類の処理により、第一 (第二) 重要地点の代表点と同様の滞在傾向で、かつ一定の割合以上の滞在時間を持つ滞留点を重要滞留点群としてまとめる。以上の処理におけるパラメータ (0.9, 30%) は本研究で用いるデータセットに対して経験的に適切な値を画一的に設定しているが、本来はユーザの生活様態に応じて最適な値を設定することが望ましい。しかしながら、最適なパラメータの決定手法の確立にはいっそうの検討を要する。

以上の方法により重要地点、および重要地点と同一の意味を持つ滞留点を推定するためにはある程度の期間の位置情報ログを収集することが必要である。本研究は提案方式により生成した特徴量のストレス推定への効果検証を目的としており、重要地点の推定は行える前提で特徴量を生成するために、5.1 節で述べるデータセットの各ユーザにおいて収集したすべての位置情報ログデータを用いて重要地点の推定を行う。こうして得られた第一 (第二) 重要地点群を示す座標のリストと、各日の位置情報ログに対し時空

表 3 周辺 WiFi 情報の例

Table 3 An example of ambient WiFi access point (AP) log.

時刻	SSID 名	MAC アドレス
2019/1/1 0:00:03	myaccesspoint-g	11:22:33:44:55:66
2019/1/1 0:00:03	otonari-home-wifi	44:55:66:77:88:99
2019/1/1 0:05:03	myaccesspoint-g	11:22:33:44:55:66
⋮	⋮	⋮
2019/1/1 12:00:03	office-wifi	66:55:44:33:22:11
⋮	⋮	⋮




図 5 第一重要地点および第二重要地点への滞在時間帯の確率密度分布 (周辺 WiFi 利用)

Fig. 5 Probability distribution of stay occurrence at the first and second important locations (based on ambient WiFi AP).

間クラスタリング手法 [20] を適用して得られた滞留点の系列を照らし合わせ、いずれかの座標の近傍 (500 メートル以内) に滞在している場合、各重要地点に滞在していると判定する。

4.2.2 周辺 WiFi 情報を用いた重要滞留点抽出

周辺 WiFi 情報は、表 3 の例で示すように観測した時間と SSID 名、MAC アドレスの組であり、空間情報は含まれていない。一方で、1 度の観測で複数の SSID 名・MAC アドレスの組を取得可能であり、観測可能な WiFi アクセスポイントは空間によって異なるため、観測したアクセスポイントの集合は、それらのアクセスポイントを観測可能な地点、すなわち固有の位置を表す情報として利用することができる。

周辺 WiFi 情報を用いて第一重要地点と第二重要地点への滞在を推定するために、図 4 で示す第一重要地点および第二重要地点への滞在時間帯分布を参考にする。図 4 より、午前 2 時から午前 6 時に最も観測された WiFi アクセスポイントを第一重要地点を表すアクセスポイント情報とし、午前 10 時から午後 4 時に最も観測された WiFi アクセスポイントを第二重要地点を表す情報とする。以上のルールにより、周辺 WiFi 情報を利用して推定した第一重要地点および第二重要地点への滞在時間帯分布を図 5 に示す。図 5 と図 4 のそれぞれの第一重要地点、および第二重要地点における Bhattacharyya 係数はそれぞれ 0.995, 0.993

であり、周辺 WiFi 情報を用いる場合においても、位置情報を用いる場合と同様の傾向で重要な位置への滞留を推定できることが分かる。

また、4.2.1 項同様に、第一重要地点および第二重要地点が複数地点存在することを考慮するために、各アクセスポイントに対し、アクセスポイントの検出頻度および検出される時間帯分布の類似度に基づいたフィルタを適用し、第一重要地点および第二重要地点と同様の滞留傾向を示すアクセスポイントかどうかを判断する。具体的には、第一（第二）重要地点の代表地点を表すアクセスポイントの検出回数に対し検出回数が 30% 以上であるアクセスポイントで、かつ 1 時間ごとの滞在時間帯分布の比較における Bhattacharyya 係数が 0.9 以上のアクセスポイントを第一（第二）重要地点群としてまとめる。

以上の方法により重要地点、および重要地点と同一の意味を持つ滞留点を推定することが可能であるが、4.2.1 項と同様に、今回は 5.1 節で述べるデータセットの各ユーザにおいて収集したすべての周辺 WiFi ログデータを用いて重要地点の推定を行う。こうして得られた第一（第二）重要地点群を表すアクセスポイント情報のリストと、各日の周辺 WiFi ログを照らし合わせ、いずれか 1 つ以上のアクセスポイントを検出できている場合に各重要地点に滞在していると判定する。

4.3 重要滞留点における特徴量生成方法

4.2.1 項および 4.2.2 項で述べた方式で抽出した各重要地点、および、その他の地点での滞在時間に対し、表 2 に示す特徴量の生成を行う。提案手法で集計対象となるログは空間的に近いログを集計するため、表 2 のうち人の移動に関する特徴量は用いないものとする。以上の方法により、3 カ所（第一重要地点、第二重要地点、その他）において各 195 種類、合計 585 個の特徴量を生成する。

5. 性能評価

5.1 データセット

本研究では提案手法による新規特徴量のストレス推定への効果検証のため、著者らの先行研究で収集した株式会社 NTT ドコモの R&D 社員 32 人の合計 554 日のデータセットを用いる。ユーザにとって重要な滞留点でのスマートフォンログはユーザの心理状態を反映するという本研究における仮説の検証のため、性能評価では第一重要地点、および第二重要地点の両方に滞在した日を対象としてストレス推定モデルを構築する。

上記データセットに対し、4.2.1 項で述べた位置情報に基づく滞留点推定をユーザごとに適用した結果、第一重要地点と第二重要地点への滞留を抽出できたログは 21 人の 212 日（高ストレス：84 日、低ストレス：128 日）であることを確認した。時間的な特徴量に基づいた従来手法との

比較手法として、位置情報を用いて空間的な特徴量を用いる場合の提案手法の効果検証のため、この 21 人・212 日のデータを用いて 5.3 節の評価を行う。一方、今回収集したデータセットに対して 4.2.2 項で述べた周辺 WiFi 情報に基づく滞留点推定をユーザごとに適用した結果、第一重要地点と第二重要地点への滞留を抽出できたログは 26 人の 269 日（高ストレス：107 日、低ストレス：162 日）であることを確認した。4.2.1 項と 4.2.2 項による提案手法における特徴量抽出方式によるストレス推定の影響の評価のため、5.4 節の評価では、上記 21 人の 212 日のデータと 26 人の 269 日のデータで共通して重要地点への滞留が抽出できている 20 人の合計 174 日（高ストレス：69 日、低ストレス：105 日）のデータセットに対して推定モデルを構築し推定精度の評価を行う。以降の 5.3 節、5.4 節の評価では、上記 2 種類のデータセットを用い、

- 本研究で提案する新特徴量の効果検証、
- 本研究での新特徴量の生成方法（位置情報または周辺 WiFi 情報を利用）の比較、

の評価をそれぞれ行う。

5.2 評価手法

先行研究 [13] で導入した合計 7,437 次元の特徴量、および本研究で提案する 585 次元の新特徴量を用いたストレス推定モデルの性能への影響評価のため、1 人抜き交差検証により新規ユーザを想定したモデルの推定精度を求める。具体的には、21 人のユーザのうち 20 人のデータを用いてストレス推定モデルを構築し、残る 1 人のデータでモデルの性能評価を行うことを 21 通りすべてのデータ分割方法で行い、21 人それぞれの性能評価結果を統合する。これにより、推定モデルの構築において評価対象ユーザのデータをまったく用いず、未知のユーザを想定した評価を行う。

推定問題はストレスが高いか低いか（＝高ストレス状態が陽性か陰性か）の二値分類問題とし、推定精度の指標は、Accuracy（陽性と陰性を合わせた全体の正解率）、Precision（適合率：陽性と検知したもののうち真に陽性である割合）、および Recall（再現率：真の状態が陽性であるもののうち検出した割合）を用いる。

5.3 空間特徴量を用いたストレス推定精度

まず、先行研究で提案した時間的観点で生成した特徴量と、本研究で提案する空間的観点の特徴量の効果の比較、および併用した際の効果検証のため、2 種類の特徴量を独立して使用した場合、および併用した場合のストレス推定精度を表 4 に示す。この結果より、時間的特徴量と空間的特徴量を比較すると、時間的特徴量を用いたストレス推定モデルの方が推定精度が高いことが分かる。この理由として、時間的特徴量の次元数が多く、ストレス推定に有効な特徴量をより多く生成できていたからと考えられる。ま

表 4 特徴量ごとのストレス推定精度 (ユーザ数 21, サンプル数 212)

Table 4 Stress estimation performance for each feature type (21 users and 212 instances).

用いる特徴量	特徴量数	Accuracy	Precision	Recall
時間の特徴量 (従来手法)	7,437	81.6%	79.2%	72.6%
空間の特徴量 (提案手法: 位置情報ベース)	585	70.3%	62.1%	64.3%
時間の特徴量+空間の特徴量 (提案手法: 位置情報ベース)	8,022	88.7%	86.6%	84.5%

表 5 ストレス推定における混同行列 (特徴量ごと)

Table 5 Confusion matrix of stress estimation for each feature type.

(a) 時間の特徴量				(b) 空間の特徴量				(c) 時間の特徴量+空間の特徴量			
		推定結果				推定結果				推定結果	
		低	高			低	高			低	高
真値	低	112	16	真値	低	95	33	真値	低	117	11
	高	23	61		高	30	54		高	13	71

た、今回のデータセットでは同じ職種のユーザを対象にストレス推定を行っているため、生活の時間帯もおおむね類似していたため、時間的観点での特徴量が有効であったと考えられる。

一方で、時間の特徴量と空間的特徴量を併用する場合、ストレスの推定精度が各指標を通じて向上しており、Accuracy が 88.7% を達成していることが確認できる。すなわち、空間的特徴量単独だと時間的特徴量の推定性能には及ばないものの、両者を組み合わせることでストレス推定に有効なより多くのパターンを抽出できたことを示唆している。したがって、時間的観点に加え、空間的観点でスマートフォンログを分析することはユーザのストレス推定において有効であったといえる。

また、表 4 の結果における推定の傾向観察のため、推定結果と真値の混同行列を表 5 に示す。混同行列の結果より、低ストレス状態と高ストレス状態の誤検出において顕著な違いが見られず、高ストレス状態を低ストレス状態と誤検出することのいずれも発生していることが確認できた。一方、表 5(a) および表 5(b) の比較により、空間的特徴量を用いる場合に対し、時間的特徴量を用いる場合における対角成分が一貫して上回っていることから、ストレスが高い状態と低い状態の両方の推定において、時間的特徴量を用いることがより有効であることが裏付けられている。同様に、表 5(a) および表 5(c) の比較を通じて、時間的特徴量に加え、空間的特徴量を用いる場合の対角成分が一貫して上回っており、ストレスの高低の推定において、時間的特徴量だけでなく空間的特徴量を考慮することが重要であることを示している。

さらに、ストレス推定において本研究で提案した空間的観点で生成した特徴量がどう作用したかを明らかにするため、SHAP value (Shapley additive explanations) を用い、各特徴量の推定への影響を算出する。図 6 に特に推定に寄

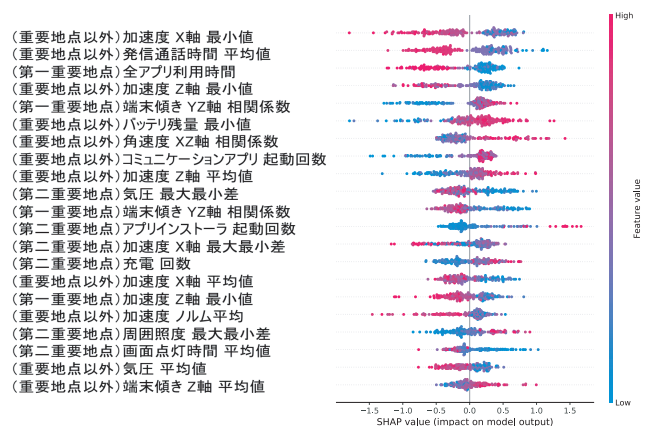


図 6 ストレス推定における空間的特徴量の影響

Fig. 6 Visualization of effect of spatial features on stress estimation.

与した特徴量の影響を可視化した結果を示す。図では縦方向に各特徴量名が、横方向に SHAP value が描画されている。図の各点は各推定サンプル (本評価ではある 1 日の特徴量の値を示す) を表しており、各点における色は特徴量の値の大小を表している。横軸 (SHAP value) は特徴量の寄与度を表しており、左側に位置するほど推定結果 (ストレスが高い確率) がマイナスになる方向に作用する。逆に、右側に位置するほどストレスが高い確率がプラスになる方向に作用する。したがって、各特徴量について、横軸に対する分布および点の色とを照らし合わせ、色が分かれている特徴量ほど、推定において有効な特徴量であることが分かる。

この結果より、各特徴量 (縦軸) が色ごとに左右に分かれて分布していることが確認できる。すなわち、特徴量の大小がストレスの高低推定において寄与していることを表しており、今回提案した重要滞在地点ごとに特徴量を生成するアプローチがストレス推定において有効であったといえる。具体的には、第一および第二重要地点だけでなく、

表 6 異なる空間特徴量集計方法におけるストレス推定精度（ユーザー数 20, サンプル数 174）

Table 6 Stress estimation performance with different spatial feature extraction methods (20 users and 174 instances).

用いる特徴量	Accuracy	Precision	Recall
時間の特徴量（従来手法）	77.6%	71.4%	72.5%
時間の特徴量+空間の特徴量 （提案手法：位置情報ベース）	81.0%	75.7%	76.8%
時間の特徴量+空間の特徴量 （提案手法：周辺 WiFi 情報ベース）	81.0%	79.0%	71.0%

その他の地点でのユーザーの行動特徴量がストレス推定において重要であることが明らかになった。さらに、加速度では平均値や最小値が大きい（動きがある）場合にストレスを低く推定する傾向が示されており、ユーザーがストレスを受けていることをスマートフォンの動きセンサから検出できる可能性が示されている。また、重要地点以外での発信通話時間が長いとストレスを低く推定する傾向がある一方で、コミュニケーションアプリの起動回数は多いとストレスを高く推定する傾向があり、コミュニケーションに関しては方法や頻度の観点で、ストレスと複雑な関係を持っていることが示唆されている。加えて、第二重要地点では周囲の明るさや気圧などの環境条件に関する特徴量も反応しており、主に活動を行う場所における環境要素も人のストレスと関連していることが明らかになった。以上の分析を通じて、先行研究で提案した時間的観点での特徴量に加え、本研究で提案した空間的観点での特徴量集計方式によりストレスと関連するユーザーの行動をとらえる可能性がより高まったと考えられる。このことは、従来手法により生成した特徴量と本研究で提案した特徴量の組合せによりストレス推定精度が向上したことからも裏付けられている。

5.4 位置情報を周辺 WiFi 情報で代用した場合

前節の評価では、スマートフォンで取得した位置情報に基づいて生成した空間特徴量によるストレス推定への効果検証を行った。本節では、位置情報に基づき生成した空間特徴量、および周辺 WiFi 情報のみを用いて生成した空間特徴量のストレス推定における効果の差を検証する。

両者の比較のため、いずれの方式でも空間特徴量生成を実施できた 20 人ののべ 174 日のデータセットを用いてストレス推定の精度の評価を行った結果を表 6 に示す。前節の評価と同様に、ベースラインとして時間の特徴量のみを用いた場合と、時間の特徴量と位置情報を利用した空間特徴量を併用する場合、および時間の特徴量と周辺 WiFi 情報を利用した空間特徴量を併用する場合のストレス推定精度を示している。この結果から、全体的なストレス高低の推定成功率（Accuracy）において、いずれの方式で生成し

た空間特徴量においても、ストレス推定精度の向上に寄与したことが確認できる。

また、Precision と Recall に着目した場合、位置情報を利用した場合はベースラインに対して一意に性能が向上しており、陽性・陰性のいずれのサンプルにおいても推定精度の向上を確認できた。一方で、周辺 WiFi を用いた場合は高ストレス時における再現率（recall）がベースラインに対して 1.5%低下している。各特徴量集計方法ごとの具体的な推定の傾向を混同行列として表 7 に示す。混同行列の結果より、高ストレス状態を低ストレス状態と誤検出することと低ストレス状態を高ストレス状態と誤検出することのいずれも発生していることが確認できる。さらに、表 7(a) および表 7(b) の比較により、位置情報ベースで集計した空間的特徴量を追加した場合は、混同行列における対角成分が一意に増加しており、各クラスの推定精度の向上が確認できる。この一方で、周辺 WiFi ベースの空間的特徴量を追加した場合（表 7(c)）では、ストレスが低いクラスを正しく推定できる割合は向上し、低ストレス状態を高ストレス状態と誤検出する数が減少しているものの、ストレスが高いクラスを正しく推定できた数は表 7(a) と比較して 1 件減少している。したがって、表 6 で示すとおり、誤認識の減少により Precision は向上したものの Recall が低下するという結果が得られている。空間的特徴量の集計方法により推定結果が異なる理由としては、重要地点に滞留しているかどうかの判定の粒度が影響していると考えられる。位置情報を用いた滞留点検出ではクラスタリングの半径を 500 メートルに設定しており、重要地点そのものだけでなく、近傍での滞在も含めて滞在と判定している。一方で、周辺 WiFi 情報を用いた滞留点検出では、重要地点固有の WiFi アクセスポイントを検出できない場合には滞在与判定しないため、WiFi 設備の配置状況によっては、部屋単位やフロア単位など、より細かい単位で重要地点かどうかの判定が行われる。したがって、実際に同じ座標に滞在していたとしても、重要地点かどうかの判定に差が生じる可能性があり、その結果、両者の特徴量が異なりストレス推定モデルの精度に影響したものと考えられる。しかしながら、いずれの特徴量を用いる場合も全体的なクラス分類精度としては向上しており、時間的観点だけでなく、空間的な観点でスマートフォンログを集約することはユーザーの状況認識において有用であるといえる。

5.5 位置情報と周辺 WiFi 情報を併用して空間特徴量を抽出した場合

前節では位置情報および周辺 WiFi 情報のそれぞれを用いて抽出した滞在情報に基づいて空間的特徴量を用いた場合の比較を行った。一方で、実際には位置情報と周辺 WiFi 情報は両方取得できていたり、片方だけ取得できているユーザーが存在すると考えられる。そのため、本節ではより

表 7 ストレス推定における混同行列 (空間特徴量集計方法ごと)

Table 7 Confusion matrix of stress estimation for each spatial feature extraction method.

(a) 時間的特徴量				(b) 時間的特徴量+空間的特徴量 (位置情報ベース)				(c) 時間的特徴量+空間的特徴量 (周辺 WiFi 情報ベース)			
		推定結果				推定結果				推定結果	
		低	高			低	高			低	高
真値	低	85	20	真値	低	88	17	真値	低	92	13
	高	19	50		高	16	53		高	20	49

表 8 特徴量ごとのストレス推定精度 (ユーザ数 26, サンプル数 336)

Table 8 Stress estimation performance with combination of location and WiFi based spatial features (26 users and 336 instances).

用いる特徴量	Accuracy	Precision	Recall
時間的特徴量 (従来手法)	81.0%	77.8%	73.1%
時間的特徴量+空間的特徴量 (提案手法)	84.2%	80.5%	79.9%

表 9 表 8 のストレス推定結果における混同行列 (特徴量ごと)

Table 9 Confusion matrix of stress estimation of Table 8.

(a) 時間的特徴量				(b) 時間的特徴量+空間的特徴量			
		推定結果				推定結果	
		低	高			低	高
真値	低	174	28	真値	低	176	26
	高	36	98		高	27	107

高い精度が期待できる位置情報により滞在が抽出できている場合は位置情報に基づいた特徴量抽出を行い、位置情報が取得できていない場合においても、周辺 WiFi 情報で滞在が抽出できた場合には周辺 WiFi 情報に基づいた特徴量抽出を行うことができた 26 人の 336 日分のデータセットにおいて、同様の評価を行った。時間的特徴量のみ用いた推定精度と、時間的特徴量に加え空間的特徴量を用いた推定精度の比較を表 8 に示す。この結果より、これまでの評価と同様に、時間的特徴量だけでなく、空間的特徴量を組み合わせるとストレス推定を行うことで、ストレス推定精度を向上させられることを確認できる。また、表 8 の結果における混同行列を表 9 に示す。この結果でも、空間的特徴量を用いる場合に混同行列における対角成分が一意に増加していることが確認できた。以上の結果より、提案手法により位置情報または周辺 WiFi 情報を用いて抽出したユーザの重要地点への滞在時のスマートフォンの利用傾向を空間的特徴量として集計し、ストレス推定に活用することの有用性を確認できた。

6. 考察

本研究では前節の性能評価のとおり、従来の時間集計方法に加え、空間集計方法に基づいてスマートフォンの利用ログを集計し得られたユーザ行動の特徴量より、ストレスの推定精度を向上させられることを確認した。一方

で、本研究では空間的観点でのログ集計がユーザの心理状態をとらえるために有効であるという仮定を置いており、そのため推定対象となるユーザや、推定を実施できる条件に制限がある。以下に詳細を述べる。

6.1 働き方による推定対象の制限

提案手法では、滞留地点の持つ意味を機械的に推定するため、よく滞在している座標やよく観測される WiFi アクセスポイント名に対して、滞在時間の傾向に基づき、寝食を行う地点や活動を行う地点などの意味づけを行う。具体的には、提案手法では推定対象のユーザの働き方について日勤を仮定しており、深夜は自宅にいる、正午付近は職場にいるという前提のもと、第一重要地点および第二重要地点を定める。すなわち、働く時間帯が日勤と異なるユーザや、働く場所が多様なユーザに対しては、第一重要地点および第二重要地点を適切に推定することができない可能性が高い。また、重要地点と定める条件として、一定以上 (全体の 3 割以上) の時間や回数の滞在を定めており、働く場所が多様なユーザに対しては、その閾値を満たさない可能性がある。働く時間帯や働く場所が変化するユーザに対する空間的観点での特徴量の集計ならびにストレス推定への利用は今後の課題であるが、より多くのユーザの実データに基づき、頻度や滞在時間帯の観点に加え、勤務日であるか・休日であるかといった情報に基づいて機械的に定めることを検討している。

6.2 推定を実施できる条件

5.1 節で述べたとおり、本研究の評価では当初に立てた仮説の検証のため、性能評価では第一重要地点、および第二重要地点の両方に滞在した日を対象としてストレス推定モデルの構築および性能評価を行った。この条件により、データセット全体の 554 日に対し、位置情報に基づく滞留点推定および周辺 WiFi に基づく滞留点推定の両方で第一重要地点と第二重要地点への滞留を抽出できたログは合計 174 日にとどまった。この原因として、主に以下の 3 つの原因が考えられる。

(1) 位置情報に基づく重要地点の推定および抽出の失敗: 提案手法の位置情報に基づく滞留点推定において、第一重要地点および第二重要地点への滞留の抽出に失敗するユー

ずは 11 人存在することを確認した。この 11 人のうち、実験期間中すべての日程において位置情報が取得できていなかったユーザが 3 人含まれる。これらの理由として、スマートフォンの位置情報の測位機能がオフになっていたか、あるいはアプリへの位置情報取得を許諾していなかったと考えられる。また、残りの 8 人においては、位置情報の取得自体はできていたものの、省電力機能などの影響で 1 日に記録される位置情報の数が平均で 15.1 回であり、第一重要地点および第二重要地点への滞留の抽出に成功した 21 人の平均 48.1 回と比較して、大幅に少なく、提案手法における重要地点の推定に失敗、もしくは推定した重要地点への滞在をうまく判定できなかったものと考えられる。

(2) 周辺 WiFi 情報に基づく重要地点の推定および抽出の失敗：周辺 WiFi 情報については、第一重要地点および第二重要地点への滞留抽出に失敗するユーザは 6 人存在することを確認した。多くのユーザで実験期間中ほとんどの日程で取得できている中で、1 人だけ周辺 WiFi 情報が取得できていなかったことが分かった。この理由としては、WiFi の利用をオフにしてしまい、周辺 WiFi 情報を取得できなかったと考えられる。また、6 人のうち 5 人においては、周辺 WiFi 情報が取得できているにもかかわらず第一重要地点または第二重要地点の滞在抽出に失敗しており、提案手法による WiFi アクセスポイント名に基づいた滞在の抽出に失敗しているものと考えられる。第一重要地点を推定できない理由として考えられるのが、自宅などの第一重要地点に WiFi アクセスポイントを設置していないことがあげられる。提案手法では自宅に WiFi アクセスポイントが設置されており、自宅に滞在している場合に特定の WiFi アクセスポイントを検出することを前提に手法を設計しているため、自宅に WiFi アクセスポイントを設置していないユーザでは自宅を表すアクセスポイントを検出することが難しい。また、第二重要地点の抽出に失敗する理由としては、勤務地が 2 カ所あり、それぞれに設置されているアクセスポイント名称が異なることや、同じ職場でも日によって働く部屋が異なるなどの理由で、検出する WiFi に差があることがあげられる。さらに、第一重要地点と第二重要地点のいずれかの推定に失敗したユーザ 5 人では、1 日あたり周辺 WiFi アクセスポイントを重複込みで 297.4 個検出できていたことに対し、第一重要地点と第二重要地点の両方の推定に成功したユーザ 26 人では、1 日あたり周辺 WiFi アクセスポイントを重複込みで 737.1 個検出できており、取得できていた周辺 WiFi アクセスポイント情報の数量にも差があり、重要地点の推定に影響したと考えられる。

(3) 各種重要地点への不滞在：提案手法では、寝食を行う地点（第一重要地点）ならびに活動を行う地点（第二重要地点）におけるスマートフォン利用の傾向を特徴量化することで、利用者のストレス推定において有効な特徴量を抽

出可能である。いい換えると、提案手法の適用条件として、第一重要地点および第二重要地点へ滞在することが求められる。今回募集した実験参加者はいずれも平日勤務で、土日祝日は休みであったため、土日祝日については第二重要地点へと滞在しておらず、評価の対象となる日数が休日の数（554 日中 85 日）だけ減少した。さらに本研究で用いたデータの取得期間は、2017 年 11 月より 2018 年 1 月で、554 日中 11 日が年末年始の休暇の時期にまたがっていたため出勤の日数が少なく、第二重要地点への滞在日数が少なくなったものと考えられる。提案手法の休日における適用については、第一重要地点での特徴量集計は容易であるものの、第二重要地点の定義において課題がある。平日の活動においては、職場など主に活動を行う場所と目的（仕事など）が定まっているものの、休日の活動においては人の行動がより多様となり、訪れる場所によって目的が異なる（買い物、娯楽、習い事など）うえに、多くの地点への滞在が予期されるため、より細かい単位で重要地点を定め、集計を行っていく必要があると考えられる。

7. まとめと今後の課題

本研究では、ユーザが日々持ち歩くスマートフォンはユーザの心理状態を反映するとの想定のもと、スマートフォンから得られるログデータを用いて利用者のストレスを推定する手法を提案した。提案手法では、時間的観点でのログ集計だけでなく、空間的観点でのログ集計がユーザの心理状態をとらえるために有効であると想定し、位置情報、および周辺 WiFi の情報を用いて空間的観点でユーザの行動を表す特徴量を集計する方式を提案した。提案手法による新規特徴量の有効性検証のため、時間的観点で集計した特徴量と組み合わせることでストレス推定モデルを構築、評価を行った結果、21 人のユーザにおいて、推定精度 88.7% で利用者のストレスの高低度合いを推定可能であることを確認し、時間だけでなく空間的観点でスマートフォンのログを集計することが有効であることを確認した。また、評価結果より、重要な滞在点でのスマートフォンログだけでなく、重要地点以外でのスマートフォンログ（動きのセンサやアプリの利用など）から得られた行動特徴量もストレスの推定に寄与することを確認した。

今回の評価では、従来研究で用いた特徴量を基準として本研究で提案した新しい特徴量の有効性の検証を行った。一方で、従来の特徴量は位置情報を用いて生成するものが含まれているため、今後の課題として、プライバシーを考慮するためにすべての特徴量で位置情報を用いない場合の精度検証を行う必要がある。

参考文献

- [1] World Health Organization: World Mental Health Day 2017, available from (<http://www.who.int/mental>).

health/world-mental-health-day/2017/en/).

[2] Cohen, S., Kessler, R.C. and Gordon, L.U.: *Measuring stress: A guide for health and social scientists*, Oxford University Press on Demand (1997).

[3] Won, E. and Kim, Y.-K.: Stress, the autonomic nervous system, and the immune-kynurenine pathway in the etiology of depression, *Current Neuropharmacology*, Vol.14, No.7, pp.665–673 (2016).

[4] 神山 剛ほか：ユーザ利用実態調査に基づくスマートフォン利用モデル, 情報処理学会論文誌コンシューマ・デバイス&システム (CDS), Vol.8, No.2, pp.84–102 (2018).

[5] Palmius, N. et al.: Detecting bipolar depression from geographic location data, *IEEE Trans. Biomedical Engineering*, Vol.64, No.8, pp.1761–1771 (2016).

[6] Saeb, S. et al.: The relationship between mobile phone location sensor data and depressive symptom severity, *PeerJ*, Vol.4, p.e2537 (2016).

[7] Fukazawa, Y., Yamamoto, N., Hamatani, T., Ochiai, K., Uchiyama, A. and Ohta, K.: Smartphone-based Mental State Estimation: A Survey from a Machine Learning Perspective, *Journal of Information Processing*, Vol.28, pp.16–30 (2020).

[8] Canzian, L. and Musolesi, M.: Trajectories of depression: Unobtrusive monitoring of depressive states by means of smartphone mobility traces analysis, *Proc. 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.1293–1304, ACM (2015).

[9] Ware, S. et al.: Large-scale Automatic Depression Screening Using Meta-data from WiFi Infrastructure, *Proc. ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, Vol.2, No.4, p.195 (2018).

[10] Kroenke, K. et al.: The PHQ-9: Validity of a brief depression severity measure, *Journal of General Internal Medicine*, Vol.16, No.9, pp.606–613 (2001).

[11] Camm, A.J., Malik, M., Bigger, J.T., Breithardt, G., Cerutti, S., Cohen, R.J., Coumel, P., Fallen, E.L., Kennedy, H.L., Kleiger, R., et al.: Heart rate variability: Standards of measurement, physiological interpretation and clinical use, *Circulation*, Vol.93, No.5, pp.1043–1065 (1996).

[12] Yamamoto, N. et al.: Physiological Stress Level Estimation Based on Smartphone Logs, *Proc. 11th International Conference on Mobile Computing and Ubiquitous Networking (ICMU)*, IEEE (2018).

[13] 濱谷尚志ほか：ストレスと注意機能の相互作用を考慮したスマートフォンログからのストレス推定手法, マルチメディア, 分散協調とモバイルシンポジウム 2019 論文集, Vol.2019, pp.759–769 (2019).

[14] Boukhechba, M. et al.: Monitoring social anxiety from mobility and communication patterns, *Proc. 2017 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proc. 2017 ACM International Symposium on Wearable Computers*, pp.749–753, ACM (2017).

[15] Cha, S.: Comprehensive survey on distance/similarity measures between probability density functions, *City*, Vol.1, No.2, p.1 (2007).

[16] Altini, M. and Amft, O.: HRV4Training: Large-scale longitudinal training load analysis in unconstrained free-living settings using a smartphone application, *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp.2610–2613, IEEE (2016).

[17] Lu, C., Zou, X., Orr, W.C. and Chen, J.: Postprandial changes of sympathovagal balance measured by heart

rate variability, *Digestive Diseases and Sciences*, Vol.44, No.4, pp.857–861 (1999).

[18] Chen, T. and Guestrin, C.: Xgboost: A scalable tree boosting system, *Proc. 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp.785–794, ACM (2016).

[19] Chawla, N.V., Bowyer, K.W., Hall, L.O. and Kegelmeyer, W.P.: SMOTE: Synthetic minority over-sampling technique, *Journal of Artificial Intelligence Research*, Vol.16, pp.321–357 (2002).

[20] Nishida, K. et al.: Probabilistic identification of visited point-of-interest for personalized automatic check-in, *Proc. 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.631–642, ACM (2014).

推薦文

ふだんから利用するスマートフォンはユーザの心理状態を反映するデバイスであるという想定の下で、スマートフォンから得られるログデータを用いて利用者のストレス推定をする手法を提案している。現代社会において重要なストレス推定という課題を、日常的に利用するデバイスを用いて推定できる方法を提案しており、実用性の点で優れているだけでなく、位置情報に基づいた特徴量を用いる点でも新規性が見られ、学術的にも価値が高い論文であるため、情報処理学会論文誌へ推薦する。

(モバイルコンピューティングとパーベイシブシステム
研究会主査 太田 賢)



濱谷 尚志 (正会員)

2013年大阪大学基礎工学部情報科学科卒業。2018年同大学大学院情報科学研究科博士後期課程修了。2017～2018年日本学術振興会特別研究員 (DC2)。現在、株式会社NTTドコモ勤務。人の行動のセンシング、状態認識、ヘルスケアに関する研究に従事。博士 (情報科学)。



落合 桂一 (正会員)

2008年千葉大学大学院博士前期課程修了。同年株式会社NTTドコモ入社。2017年東京大学大学院工学系研究科博士後期課程修了。2020年8月より東京大学特任助教。博士 (工学)。SNS, 位置情報, ヘルスケアデータやスマートフォンログ解析の研究開発に従事。ACM, 日本データベース学会各会員。



山本 直樹

2014年金沢大学理工学域電子情報学類卒業。2016年同大学大学院自然科学研究科電子情報科学専攻博士前期課程修了。2016年株式会社NTTドコモ入社。2021年クロステック開発部勤務。ユーザの状態認識、モバイルヘル

スケアに関する研究に従事。



深澤 佑介 (正会員)

2004年東京大学大学院工学系研究科修士課程修了。同年株式会社NTTドコモ入社。2011年東京大学大学院工学系研究科博士後期課程修了。2011年より東京大学人工物工学研究センターにて協力研究員、2016年より客

員研究員を兼任。2019年より早稲田大学イノベーション研究所招聘研究員を兼任、現在に至る。Webマイニング、パーソナライゼーション、確率モデルに関する研究開発を行っている。IEEE, 人工知能学会各会員。博士(工学)。



木本 勝敏

1991年北海道大学大学院工学研究科精密工学専攻修士課程修了。同年株式会社NTTドコモ入社。入社以来移動通信システム・サービスの研究開発に従事。



上西 康平

2014年東京大学工学部精密工学科卒業。2016年同大学大学院工学系研究科精密工学専攻修士課程修了。2019年同専攻博士課程修了。同年同大学院工学系研究科人工物工学研究センター

特任研究員。ヒトの姿勢制御のモデリング、人の行動の解析に関する研究に従事。博士(工学)。



太田 順

1989年東京大学大学院工学系研究科精密機械工学専攻修士課程修了。同年新日本製鐵(株)入社。1991年東京大学工学部助手。1994年同講師。1996年東京大学大学院工学系研究科精密

機械工学専攻助教授。2007年同准教授。2009年4月同教授。同年6月東京大学人工物工学研究センター教授。2019年東京大学大学院工学系研究科教授。2015年より華南理工大学客員教授。この間1996~1997年Stanford大学Center for Design Research客員研究員。日本ロボット学会フェロー。マルチエージェントロボット、身体性システム科学、大規模生産/搬送システム設計と支援、人の解析と人へのサービスの研究に従事。博士(工学)。



寺澤 悠理

2010年慶應義塾大学大学院社会学研究科心理学専攻博士課程を修了し、同大学院より博士(心理学)を取得。(独)国立精神神経医療研究センター精神生理研究部、脳病態統合イメージングセン

ターにおける研究員を経て、2014年4月より慶應義塾大学文学部心理学専攻助教。2019年4月より同准教授。専門領域は、認知神経科学および神経心理学。主たる関心は主観的感情の認知神経システムにあり、人間の感情を心と脳そして身体がどのように作り出しているのかを研究している。



沖村 宰

1995年東京大学工学部計数工学科卒業。2005年東京医科歯科大学医学部卒業。2016年慶應義塾大学医学部医学研究科博士課程修了。博士(医学)。

現在、長谷川病院精神科医師。慶應義塾大学医学部精神・神経科学教室特任助教。昭和大学発達障害医療研究所兼任講師。日本精神神経学会精神科専門医・指導医。専門は臨床精神医学、計算論的精神医学。



前田 貴記

1995年慶應義塾大学医学部卒業。博士（医学）。現在、慶應義塾大学医学部精神・神経科学教室専任講師。日本精神神経学会精神科専門医・指導医。東京大学大学院工学系研究科精密工学専攻客員研究員。早稲田大学大学院文学研究科非常勤講師。専門は精神医学，神経科学。