

スマートフォンセンサログとアプリ履歴からの 不安度予測モデルの構築

伊藤拓^{†1} 深澤佑介^{†2} 沖村宰^{†3} 山下祐一^{†4} 前田貴記^{†3} 太田順^{†1}

概要: 本研究では、スマートフォンに搭載された加速度・回転・照度・画面センサのログと、アプリケーションのアクセス履歴を用いて、不安度の増減予測を行った。予測にあたり、センサログと、アプリケーションへのアクセスログとを組み合わせ、スマートフォンへアクセスしている状況を加味したアクセスの特徴量を設計した。これにより、不安状態に強い影響を与える、アプリケーションのカテゴリと、アクセス状況との組み合わせを発見できた。Random Forest により不安度増減を予測し、7割強の精度を得られた。また、特徴量の重要度を計算し、考察することにより、提案特徴量の妥当性を確認した。

キーワード: メンタルヘルス, 不安, スマートフォン, State Trait Anxiety Inventory, Random Forest,

Proposal of the Prediction Model of Anxiety Using Sensor Logs and Application History

TAKU ITO^{†1} YUSUKE FUKAZAWA^{†2} TSUKASA OKIMURA^{†3}
YUICHI YAMASHITA^{†4} TAKAKI MAEDA^{†2} JUN OTA^{†1}

Keywords: Mental Health, Anxiety, Smartphone, State Trait Anxiety Inventory, Random Forest

1. 序論

近年、メンタルヘルスへの関心が高まっている。2016年にはWHOと世界銀行が合同会議を行い、メンタルヘルスについて議論を行った[1]。

メンタルヘルスについて議論する上で、心理面での症状(精神症状)としては、憂鬱・不安・怒り・幻聴が存在する[2]。この中で、不安は本来必要な機能である。しかし、必要のないときに、必要以上の強さで作動し、コントロール不能となり、生活に支障をきたすようになると、不安障害という病気となる[3]。

不安障害は、うつ病などの重大な併発症を引き起こし、早く症状が現れるため、社会的重要度が高い[4]。最近では、精神症状が発現する前に、組織や労働者を健康な状態に導く、という0次予防がメンタルヘルスで注目されている[5]。0次予防の観点からは、精神障害が発現する前の、健全な状態において、精神障害を未然に防ぐことが重要であり、そのためには、過剰な不安が生じないようにすることが重要である。過剰な不安が生じないための対策として、「バイオフィードバック」が存在する[6]。バイオフィードバックとは、体内状態を適切な計測器によって測定し、その情報を画像や音の形で自身が意識できるよう呈示することにより、従来制御することが不可能であると考えられてきた諸機能を意図的に制御する技術である。バイオ

フィードバックを用いて不安の変化を呈示することにより、不安が高まっているときに意識させ、過剰な不安が生じることを防ぐことができると考えられる。

以上の理由から、自覚のない段階で早期に不安症状を発見することが重要である。つまり、自覚できていない無意識な不安を、意識させ、自覚を持たせることが重要である。従来、不安を自覚させるための手段として、上記のようなストレスチェックを行うという方法があるが、時間と手間がかかるため、日常生活で連続的に行うのは困難である。

日常に潜む不安に関連するものとして、近年話題になっているのが Social Network Service (SNS)によるストレスである。SNSによって常時人とコミュニケーションをとることが可能になり、便利になった一方で、そのことによる精神的負担が大きく、不安を抱えるというケースが存在する[7]。このように、スマートフォンへのアクセスが不安と密接に関わっている。

そこで、本研究の目的を「スマートフォンのアクセスログから、日常生活における無意識な不安の変化を予測すること」とする。目的を遂行するため、2つのアプローチを行う。1つ目は、多様なセンサログ・イベントログから、適切な仮説に基づき、不安と関係のあるカテゴリを設定し、そのカテゴリが日常の中でどの程度出現したかを特徴とする。たとえば、スマートフォンを操作しているときの明るさが不安と関係するという仮説を考える。この場合「暗い」

†1 東京大学
The University of Tokyo.
†2 (株)NTT DOCOMO
NTT DOCOMO, Inc.

†3 慶應義塾大学
Keio University
†4 国立精神・神経医療研究センター
National Center of Neurology and Psychiatry

「明るい」といったカテゴリ特徴を考え、他のセンサ・イベントのカテゴリと組み合わせることで、不安の変化と関係の強いカテゴリ特徴を見つける。たとえば、「暗いところでずっと SNS へアクセスしている」と不安が増す、といった傾向を発見することを目指す。2 つ目は、全員で共通した予測モデルのほかに、スマートフォンの利用ログに近いユーザクラスごとの予測モデルを構築する。スマートフォンの利用ログによってユーザをクラスタリングし、スマートフォンへのアクセスの性質が似通ったクラスごとに学習と予測を行う。クラスタリングによって、スマートフォンアクセスと不安との関係が似通ったクラスが形成されることを期待し、共通モデルにおける個人間の差異の問題と、個人モデルにおける新規ユーザに対する汎化性の問題の両方の解決を目指す。

2. 関連研究

本章では、スマートフォンを用いたメンタルヘルスの研究について述べる。

センサを用いた研究として、スマートフォンに搭載された加速度センサを用いて、うつ患者と非うつ患者とを区別する研究[8]がある。この研究では、加速度データを 10 秒ごとに分割してフーリエ変換し、平均と分散を出すことによって特徴量としている。また、GPS によって得られる位置情報を用いてうつ度合いの指標である PHQ スコアの増減を予測する研究[9]がある。この研究では、取得した位置情報から、1 日ごとに総移動距離、2 地点間の最大距離、巡回角度、移動距離の標準偏差、自宅からの最大距離、総訪問箇所、重要な滞在場所の総数という 8 つの特徴量を抽出し、PHQ スコアの増減を予測している。

スマートフォンを用いた研究では、スマートフォンの利用自体に着目し、メンタルヘルスとの関係性を調べた研究も存在する。スマートフォン分離不安障害を調べた研究[10]では、実験協力者に対して簡単な作業を行わせ、スマートフォンを手元に持たせている状態と、没収した状態では、没収した状態のときに大きく作業効率落ち、不安度も増したという報告がされている。また、具体的なアプリケーションを対象とした研究としては、Facebook の利用状況と落ち込みやすさとの関係を調べた研究[7]があり、利用時間の長い人は気分が落ち込みやすくと述べられている。すなわち、Facebook のようなアプリケーションへのアクセスが増えると、気分が落ち込みやすくなるだけでなく、そうした行動がスマートフォンへの依存を深めることになる。

スマートフォンを用いたメンタルヘルスの研究を俯瞰したが、抑うつ・ストレスを予測する研究はあるものの、早期発見が重要である不安の研究は少ない。スマートフォン分離不安障害に関する研究は存在するが、日常においてスマートフォンを手元から分離した状態はあまり多くない。日常におけるスマートフォンアクセスから、不安変化を予

測するための特徴を設計することが必要であるといえる。

3. 問題設定

今回、不安度の正解データとして、4 択問題 20 問からなる State-Trait Anxiety Inventory(STAI)[11]を用い、合計スコアを不安度の大きさとする。STAI は短い期間における不安度を示す指標として用いられている。1 問 1 点～4 点で評価され、合計スコアが 20 点～80 点となる。STAI スコアが高いほど、不安度が高いことを示している。今回 PHQ ではなく STAI を指標とした理由は、PHQ の対象が抑うつ状態であり、健常人の不安を対象とする今回の研究に適さないからである。本研究では 1 日 1 回 STAI を答えてもらうことにより、その日のセンサログ・アプリ履歴と紐付けを行う。本研究では、不安の変化を予測したいため、予測したい対象は、STAI のスコア自体ではなく、スコアが前日と比べて上がったか下がったかという 2 値である。システムの評価は、STAI スコアの増減がどの程度の精度で予測できたか、で行う。図 1 に、イメージを示す。このイメージは、スマートフォンの利用ログから、翌日の STAI スコアが上がるか、下がるかのどちらかを予測するという本研究のシステムを表している。



図 1 本研究における予測問題のイメージ
Figure 1 Image of Anxiety Prediction Problem

4. 特徴量の設計

4.1 センサの種類とデータ構造

本章では、STAI スコアの増減を予測するために、スマートフォンのログから、不安度と関係のある特徴量を設計する方法について述べる。

使用したスマートフォンは Android OS 搭載機種であり、使用したセンサは、照明センサ・加速度センサ・回転ベクトルセンサの 3 つであり、0.5 秒ごとに値を記録している。アクセス履歴については、画面のオンオフと、各アプリが起動中かそうでないかを、同じく 0.5 秒ごとに記録している。これらのログデータから複数の特徴を抽出し、特徴同士を組み合わせることで新たな特徴を計算する。ログデータのデータ構造を表 1 に示す。画面オンのログは、0 が画面オフ、1 が画面オンを表している。また、アプリの欄は、アプリケーションを起動していないときには空欄が、何かアプリを起動しているときにはそのアプリ名が保存されるよ

うになっている。

表 1 センサ・イベントログのデータ構造

Table 1 Data Structure of Sensor Logs and Event Logs

	明るさ	x軸加速度	y軸加速度	z軸加速度	x軸傾き	y軸傾き	z軸傾き	画面オン	アプリ
2016/2/14 10:00:00.000	320	0.605	-0.203	2.356	0.233	-0.126	-0.409	0	
2016/2/14 10:00:00.500	1420	-0.524	0.124	0.143	0.343	-0.299	0.192	0	
2016/2/14 10:00:01.000	560	6.378	2.143	9.243	-0.142	0.455	-0.308	1	LINE
2016/2/14 10:00:01.500	160	-3.023	-0.133	0.343	0.133	-0.977	-0.422	1	LINE
2016/2/14 10:00:02.000	80	2.422	0.143	1.243	0.658	-0.869	-0.142	0	

上記ログデータから、特徴量を抽出する。問題設定の章で述べたように、1日1回 STAI に回答してもらい、翌日スコアが上がるか、下がるかをその日のラベルとして設定し、そのラベルデータと特徴量データとを紐付けることにより、特徴量からラベルを予測する。ラベルが1日につき1つ割り当てられているので、それに対応した1日を単位とする特徴量を設計するのが自然であるが、1日という単位では特徴量が丸められすぎてしまい、予測を行うのが困難であると考えたため、特徴量は1時間おきに計算した。たとえば、2月14日に、翌日の STAI スコアが「上がる」とラベリングされていた場合には、2月14日0時~1時、1時~2時、2時~3時のデータに対してすべて「上がる」とラベリングする。その後、ラベリングされた1時間ごとのデータに対して、特徴量を計算する。

1時間ごとに特徴量を計算するにあたり、本研究では、ログデータの連続量を、特徴を表すカテゴリ量に変換し、そのカテゴリ量が1時間でどれだけ現れたかを特徴量として扱う。たとえば、ある瞬間に着目し、明るさが「明るい」のか「暗い」のか、姿勢が「まっすぐ」なのか「傾いている」のかといったカテゴリ分けをし、そのカテゴリが1時間の中で何秒現れたかを特徴量とする。この方針は、予測に効果的なラベル設定が難しいという問題があるが、設定したカテゴリが、予測したいラベルと強い相関があるときには効果的である。

4.2 カテゴリ量を用いた特徴量の設計

(1) 明るさの特徴

明るさは、得られた照度に応じて「暗い」「中程度」「明るい」の3段階に分けた。暗いところでのスマートフォンへのアクセスと、明るいところでのスマートフォンへのアクセスでは、その用途が異なると考えられるからである。段階分けの閾値は、表2のとおりである。

JIS 照明基準は「精密な作業に必要な照度」を 300lux と

表 2 明るさの特徴の基準

Table 2 Criteria of Feature of Brightness

特徴	基準
暗い	~300lux
中程度	300~1000lux
明るい	1000lux~

している。また、ルクスの目安については条件により異なり一概には言えないが、オフィスでの作業で十分な明るさを確保しているといえる明るさがおおむね 1000lux である。このことより、閾値を 300lux と 1000lux で設定した。

(2) 加速度の特徴

加速度は、x 軸、y 軸、z 軸の加速度から、3 軸における加速度の絶対値を計算した。これにより、方向によらない加速度の大きさを取得し、加速度の大きさによって「静止・一定速度」「緩やかな動き」「激しい動き」の3段階に分けた。歩きスマホが近年話題になっているように、動きながらスマートフォンへアクセスしているのか、止まってアクセスしているのかは、その人の不安と関係があると考えられるからである。加速度の基準については、明確にどこからが激しい動きなのか、ということをも明確に定めるのは難しく、行動計測の研究においても統一的な見解は得られていない。そこで本研究では、自分で実際にスマートフォンをもって操作し、得られたデータによって閾値を設定した。閾値は表3のとおりである。

表 3 加速度の特徴の基準

Table 3 Criteria of Feature of Acceleration

特徴	基準
静止・一定速度	~2 m/s ²
緩やかな動き	2~5 m/s ²
激しい動き	5 m/s ² ~

(3) スマートフォンの傾きの特徴

スマートフォンの傾きは、3 軸のうち、x 軸からの傾きを使用した。これは、スマートフォンを使用する際、ほとんどの場合では立って使うか、座った状態で使うが、その際、手首のスナップで変化するのは、x 軸方向の傾きであって、使用する状態によって y 軸や z 軸は大きく変化しないと考えられるからである。x 軸からの傾きに応じて「地面と平行」「斜め」「地面と垂直」の3段階を設定した。スマートフォンを使用しているときの姿勢は、リラックスしているのか、緊張しているのかといったその人の精神状態と関係があると考えられるからである。閾値は表4のとおりである。

表 4 傾きの特徴の基準

Table 4 Criteria of Feature of Angle

特徴	基準
地面と平行	0° ~30°
斜め	30° ~60°
地面と垂直	60° ~90°

(4) アプリケーションへのアクセスの特徴

アプリケーションへのアクセスは、どういったカテゴリのアプリケーションへアクセスしているかを特徴とした。アプリケーションのカテゴリごとに、そのアクセス時間と不安度の増減との関係が似通った性質を示すとの考えに基づいている。たとえば、Twitter や Facebook といった

SNS系アプリへアクセスするのと、ゲームや音楽アプリといった娯楽系アプリへアクセスするのでは、明らかにスマートフォンへアクセスする目的は異なっている。したがって、不安度との関係もアプリケーションのカテゴリごとに違うと考えられる。アプリケーションのカテゴリは、「SNS系アプリ」「情報取得系アプリ」「メール」「娯楽系アプリ」の4つに設定した。各カテゴリの説明と、含まれるアプリケーションの具体例は表5のとおりである。

表5 アプリケーションの特徴の基準
 Table 5 Criteria of Feature of Application

特徴	基準
地面と平行	0° ~30°
斜め	30° ~60°
地面と垂直	60° ~90°

(1)~(4)で説明したカテゴリ特徴を組合せ、「スマートフォンへアクセスしているときの操作状態の特徴」を設計する。組合せのイメージを表6に載せる。

表6 特徴の組合せのイメージ
 Table 6 Image of Combination of Feature Values

明るさ	加速度	傾き	アプリの種類
暗い	静止・一定速度	地面と平行	SNS系アプリ
中程度	緩やかに動く	斜め	情報取得系アプリ
明るい	激しく動く	地面と垂直	メール 娯楽系アプリ

特徴を組み合わせることで、アプリケーションへのアクセス状態をより詳細に記述することができる。たとえば、「暗い」「静止・一定速度」「SNS系アプリ」という3つの特徴を組み合わせることで、「暗いところで、じっとしながらSNS系アプリへアクセスする」という特徴を考えることができる。これにより、単純にアプリケーションへのアクセスという特徴だけでは発見できない、不安と大きく関係するスマートフォンへのアクセス動作を発見できることを期待する。

次に、組み合わせた特徴のうち、不安度を予測する際にどの特徴を使うか、について述べる。単純に、4種類の特徴を組み合わせただけでは、不安度の増減を予測できない可能性がある。それは、特徴同士の組合せに意味がない場合である。たとえば、SNS系アプリへのアクセスに着目したとき、不安なときには「暗いところでじっとしながらアクセスしている」のに対し、不安から解放されたときには「明るいところで歩きながらアクセスしている」という傾向があるとすると、その場合、特徴を組み合わせることで、不安度の増減予測に役立つ。しかし、娯楽系アプリへアクセスしているときには、そのアクセス状態に関わらず、不安度が下がっている状態である、という傾向がある場合、組み合わせた特徴に意味はない。意味

表7 変換後のデータ構造

Table 7 Data Structure after Translation

日時	明るさ	加速度	傾き	アプリ
2016/2/14 10:00:00.000	中程度	緩やかな動き	地面と平行	
2016/2/14 10:00:00.500	明るい	静止・一定速度	地面と垂直	
2016/2/14 10:00:01.000	中程度	激しい動き	地面と平行	SNS系アプリ
2016/2/14 10:00:01.500	暗い	緩やかな動き	地面と平行	SNS系アプリ
2016/2/14 10:00:02.000	暗い	緩やかな動き	斜め	

がないだけでなく、「娯楽系アプリを使用している時間」という特徴を細分化してしまうことで、組み合わせた1つあたりの特徴量の値が小さくなってしまい、かえって予測に悪影響を及ぼす。したがって、どの特徴を組み合わせ、どの特徴は単独で用いるか、ということが予測を行う上で重要である。

そこで、本研究においては、予測に用いる特徴のパターンを複数用意し、それぞれのパターンを用いて予測を行い、どのパターンでの予測が高精度であったかを調べる。

以下に、各パターンを列挙するが、それに先立ち、ログデータからカテゴリ特徴へ変換したあとのデータ構造について述べる。明るさ、加速度、傾き、アプリアクセスについて、表1のデータは以下の表7のように変換される。このデータを用いて、特徴量の設計を行う。特徴量は、上記特徴の組合せ条件を満たす時間が、1時間の中で何秒あるかである。たとえば、「明るいところで、スマートフォンが地面と平行になっている状態で、メールへアクセスしている」という特徴を考えた場合、3/19の15:00-16:00にはその状態が何秒あったか、16:00-17:00には何秒あったか、という時間を特徴量とする。

表8に、1時間ごとの特徴量を計算したデータがどのような構造をしているかを載せる。表8のように、特徴ごとに、1時間の中でその特徴が何秒あらわれたのかを特徴量としている。本研究では、センサログ・イベントログから得られた特徴のほかに、曜日と時間も特徴として加えている。これは、不安度の変化と、曜日・時間に関係があると考えられるからである。たとえば、週末は不安が下がる、不安なときは深夜のスマートフォン利用が増える、といった要因が考えられる。曜日・時間のみを特徴として考慮したパターンと、提案特徴を考慮したパターンを比較することで、提案特徴の効果を検証する。

曜日は、日曜日~土曜日の7つを特徴として捉え、その日が曜日に合致していればその曜日の特徴量を1とし、それ

表8 特徴量データの構造

Table 8 Data Structure of Feature Values

日時	明るさ	加速度	傾き	アプリ
2016/2/14 10:00:00.000	中程度	緩やかな動き	地面と平行	
2016/2/14 10:00:00.500	明るい	静止・一定速度	地面と垂直	
2016/2/14 10:00:01.000	中程度	激しい動き	地面と平行	SNS系アプリ
2016/2/14 10:00:01.500	暗い	緩やかな動き	地面と平行	SNS系アプリ
2016/2/14 10:00:02.000	暗い	緩やかな動き	斜め	




図2 時刻の円環表現のイメージ

Figure 2 Image of Expression of Time Using the Circle

以外を0とする。時間は、 \sin と \cos の2次元で表す。これは、時刻の円環表現と呼ばれるもので、23時と0時が、時間的には連続なのに数値上は不連続であるという問題を解決している。イメージを図2に示す。0時を $\theta=0$ としたとき、0時からの時刻を θ で表現し、その \sin と \cos で時刻を表す。たとえば、深夜3時であれば、 $\theta = 3/4$ であるので、 \sin 時間を、 \cos 時間を0.71と表す。

以上の議論を踏まえ、特徴の組合せパターンを複数提案する。はじめにパターンをすべて列挙し、その後各パターンの説明を行う。

曜日・時間

曜日・時間・明るさ 曜日・時間・加速度

曜日・時間・姿勢

曜日・時間・明るさ・加速度・姿勢

曜日・時間・明るさ×加速度×姿勢

曜日・時間・アプリ

曜日・時間・明るさ・加速度・姿勢・アプリ

曜日・時間・明るさ×アプリ・加速度×アプリ・姿勢×アプリ

曜日・時間・明るさ×加速度×姿勢・アプリ

曜日・時間・明るさ×加速度×姿勢×アプリ

上の記号で、「・」は特徴をそれぞれ単独に扱うことを、「×」は特徴を組み合わせることを意味している。たとえば、「明るさ・アプリ」というパターンであれば「暗い」「中程度」「明るい」「SNS系アプリ」「情報取得系アプリ」「メール」「娯楽系アプリ」の7種類の特徴から構成されることを意味する。一方、「明るさ×アプリ」であれば「暗い×SNS系アプリ」のように、2つの特徴を組み合わせたものを1つの特徴としているので、 $3 \times 4 = 12$ 種類の特徴から構成されることを意味する。

曜日・時間

特徴として、曜日と時間のみを採用するパターン。本研究では、このパターンをベースラインとし、このパターンと提案特徴を採用したパターンとの精度比較を行う。

曜日・時間・明るさ

曜日・時間・加速度

曜日・時間・姿勢

特徴として、のパターンに加え、それぞれ「明るさ」「加速度」「姿勢」を単独に加えたものである。と比較することで、それぞれの単独の特徴の不安予測における効果を見ることができる。

曜日・時間・明るさ・加速度・姿勢

曜日・時間・明るさ×加速度×姿勢

に、「明るさ」「加速度」「姿勢」をすべて加えたものである。は、それぞれを並列に並べているのに対し、は3つの特徴をすべて組み合わせている。もしもがより精度が良いのであれば、この3つの特徴は、単独よりも、組み合わせの特徴が不安と関係していることになる。

曜日・時間・アプリ

にアプリケーションの特徴を加えたパターン。と比較することで、アクセスしているアプリケーションのカテゴリが不安度の変化と関係あるかを見ることができる。

曜日・時間・明るさ・加速度・姿勢・アプリ

曜日・時間・明るさ×アプリ・加速度×アプリ・姿勢×アプリ

スマートフォンの操作状態に関する特徴と、アプリケーションに関する特徴を組み合わせたものである。とを比較することで、不安度の変化が、アプリケーションへのアクセス状態との組み合わせと関係するのを見る。たとえば、SNS系アプリの中でも、特に「暗いところでのSNS系アプリへのアクセス」が不安度に関係しているのだとすれば、の精度が上がると考えられる。

曜日・時間・明るさ×加速度×姿勢・アプリ

曜日・時間・明るさ×加速度×姿勢×アプリ

との比較において、アクセス状態同士を組み合わせたパターン。とを比較する目的は、とを比較する目的と同じである。と、とを比較することで、アプリケーションという特徴を加えたときに、アクセス状態の3特徴をどう組み合わせるべきかを調べる。

5. 実験手順とユーザのクラスタリング

本章では、具体的な実験手順と、序論で述べたように、実験対象をクラスタリングし、複数のクラスタを生成する方法について述べる。

5.1 実験対象

人数：20名

年齢：20歳～24歳

性別：男性15名 女性5名

協力者は全員、精神障害の既往歴はない。また、本実験は東京大学倫理委員会の承認を受けて行った。また、研究の目的、概要について協力者にすべて説明し、その結果を

論文等で発表する旨、同意を得ている。

5.2 STAI スコアと特徴量データとの紐付け

はじめに、実験協力者に対し、ログ収集アプリケーションをスマートフォンにインストールしてもらい、1日1回 STAI アンケートに答えてもらう。こうして、毎日1回、協力者からスマートフォンログと STAI の結果を取得する。

以上の作業を、1か月間続けるように依頼し、実験開始から1か月経過した時点で実験終了を通知し、アプリケーションをアンインストールしてもらう。これで、実験協力者にしてもらう工程はすべて終了である。

第4章で述べたように、提案した特徴量は1時間ごとの値である。そのため、1日ごとに得られる STAI のデータについても、1時間ごとのデータにラベル付けする必要がある。本研究では、ある日のスマートフォンログから、次の日の STAI スコアが上がるのか下がるのかを予測することが目的であるため、データにラベル付けする STAI の特徴も、「up」「down」の2種類である。そこで、翌日に STAI スコアが上がる日には、その日のデータに対して「up」、下がる場合にはデータに対して「down」とラベル付けを行う。たとえば、2月14日の STAI スコアが43点、2月15日の STAI スコアが56点である場合、2月14日は翌日の不安度が上がっているため、「up」となる。よって、2月14日の全特徴量データについて、「up」というラベル付けを行う。このラベル付けを全日数に対して行うことで、スマートフォンの利用特徴量と、STAI スコアの増減とが紐づいたデータを構築する。その後、複数人のデータを結合するため、標準化を行う。標準化は、全日程のデータの中で、特徴量の平均値を0、標準偏差を1としたときに、特徴量がいくつになるのかを計算する。標準化したあとの特徴量データの一例を表8に示す。

表8 標準化したあとの特徴量データ

Table 8 Data of Feature Values after Standardization

特徴	STAI スコア 日曜日 増減	土曜日	sin時間	cos時間	平均加速度	傾い				
						傾い	中程度 激しい動き	傾い	傾い	
2016/2/14 10時	up	1	0	0.069	-0.665	-1.015	0.670	-0.257	2.033	2.200
2016/2/14 11時	up	1	0	0.260	-0.966	-0.293	-0.190	0.027	0.500	-0.800
2016/2/14 12時	up	1	0	0.000	-1.000	1.661	-0.640	0.013	0.300	0.200
2016/2/14 13時	up	1	0	-0.257	-0.966	-0.353	3.557	2.137	-1.000	-2.500

5.3 利用ログによるクラスタリング

本節では、20名の実験協力者を利用ログによってクラスタリングする手順について述べる。利用ログによるクラスタで、クラスタ間に不安との関係に差異があれば、クラスタリングによって、全員共通の予測モデルよりも高精度な予測を行えると考えられる。

クラスタリングには、機械学習分野で一般的に用いられている k-means 法を用いる。k-means 法は、非階層型のクラスタリング手法で、クラスタの平均を用いてクラスタへの分割を行う。クラスタ数は、3に設定した。各クラスタ

表9 1時間ごとのアプリケーション利用時間平均

Table 9 Average Application Access Time per Hour

	クラスタ1	クラスタ2	クラスタ3
SNS系アプリ	39.70	6.43	448.98
情報取得系アプリ	31.69	5.75	173.75
メール	3.32	1.51	11.17
娯楽系アプリ	2.40	2.43	90.58
アプリケーション合計	77.11	16.13	724.49

の人数の割り当ては以下ようになった。

クラスタ1 10名 / クラスタ2 2名 / クラスタ3 8名
次に、各クラスタの特徴について述べる。スマートフォンへのアクセスと、不安度との関係がクラスタによってどのように異なるのかを調べるため、スマートフォンのアプリケーションへのアクセス時間の、クラスタごとの平均を表9に載せる。第3章で述べたように、今回の研究では特徴量を1時間ごとに計算している。この表は、各カテゴリに該当するアプリケーションへ、1時間あたり平均で何秒アクセスしたかを、クラスタ内で平均したものを表している。たとえば、クラスタ3であれば、該当する8名は、平均して1時間あたり約450秒(7分30秒)SNS系アプリへアクセスしていることがわかる。表9より、クラスタ1は標準的なクラスタ、クラスタ2はスマートフォンへのアクセスが少ないクラスタ、クラスタ3はスマートフォンへのアクセスが非常に多いクラスタであると解釈できる。

6. 評価

6.1 学習アルゴリズムと評価指標

本研究では、機械学習を用いて、特徴量から STAI スコアの増減を予測する。今回、機械学習による分類問題を解くにあたって、Random Forest を用いた。Random Forest は、決定木アルゴリズムを拡張したものであり、分類問題のほか、回帰問題も解くことができる。Random Forest を今回使用した理由としては、説明変数が多くても過学習を起こしにくいことと、説明変数の重要度を計算できることが挙げられる。今回は、特徴を組み合わせて、複数のパターンを網羅的に学習していくため、説明変数が多くなってしまふ。そのため、説明変数が多すぎることによる弊害が少ないアルゴリズムが求められる。また、今回予測を行う上で、どの特徴が予測の上で効果的だったのかを求めることが重要であるため、説明変数の重要度を計算できるアルゴリズムが必要であった。以上の点から、今回は Random Forest を用いた。

6.2 共通モデルによる提案パターン間の F 値による評価

機械学習の分野において、分類器の予測精度を表す指標として F 値が一般的に用いられている。F 値は、適合率と再現率という2つの指標の調和平均であり、全体としてどの程度の精度で予測できたかを表している。はじめに、スマートフォンの操作状態に関する特徴パターン間での比較を、全員共通の予測モデルにて行った。10回の交差検証

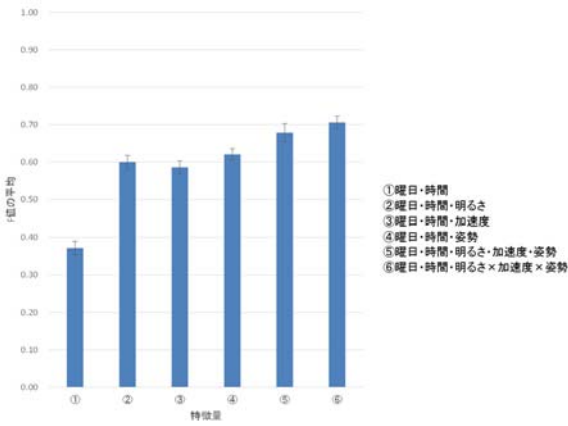


図3 パターン ①～⑥ の F 値の比較

Figure 3 Comparison of F value between Pattern1-6

の平均と標準偏差を図3に載せた。縦軸は予測全体のF値である。

単純に曜日と時間を説明変数として不安度の増減を予測すると3割後半ほどにしか予測ができないが、明るさ・加速度・姿勢といった操作状態の特徴を加えることで、予測精度が2割以上向上している。これは、明るさ・加速度・姿勢が不安度の増減と関係しているからであると言える。

また、⑥の予測精度がもっとも高いことから、3つの特徴が単独で不安と関係しているのではなく、その組み合わせが不安と関係していることによると推察できる。たとえば、「暗い」「静止・一定速度」という別々の特徴ではなく、「暗いところでじっとしている」という特徴こそが、不安度の増減に関係しているのだと言える。

続いて、上記3特徴に、アプリケーションへのアクセスという特徴を加えたパターンについて、F値の比較を行った。10回の交差検証の平均と標準偏差を図4に載せた。縦軸は予測全体のF値である。

①と⑥との差について検討する。⑥は①と比べて精




図4 パターン ①, ⑤～⑪ の F 値の比較

Figure 4 Comparison of F value between Pattern1 and 5-11 度が向上している。⑥との差が出ているのは、⑪にアプリ

ケーションの特徴を加えたことによる効果であると言える。したがって、アプリケーションの特徴が不安度増減の予測にとって適した特徴であることが分かる。一方で、①とはほとんど差がない。⑥は、①の各特徴にアプリケーション特徴をかけたものであるが、これは不安度の増減予測にとってあまり意味をなしていないことがわかる。つまり、「明るいところでSNS系アプリを使用している」「動きながら娯楽系アプリを使用している」というような、アプリケーションのカテゴリとその状態との組み合わせは、特に不安度の増減と関係がないと考えられる。②と③との比較についても、同様のことが言える。また、アプリケーションを、他の特徴と組み合わせることによる効果は、②と③とで比較ができるが、精度が②>③となっていることより、アプリケーションへのアクセスの特徴が、その操作状態の組合せと関係が弱かったことを意味する。

6.3 クラスタごとのモデルと共通モデルとのF値の比較

本節では、クラスタごとの予測モデルと、全員共通モデルとのF値との比較を行う。精度比較は、全員共通モデルでもっとも精度のよかった「曜日・時間・明るさ×加速度×姿勢・アプリ」パターンで行った。10回の交差検証の平均と標準偏差を図5に載せた。縦軸は予測全体のF値であり、横軸は左から、クラスタ1、クラスタ2、クラスタ3、全員共通の4パターンである。




図5 クラスタ間のF値の比較

Figure 5 Comparison of F value between Clusters

クラスタ3のF値は0.78、全員共通のF値は0.73であるから、クラスタリングによって、5%の精度向上が見られたことになる。また、精度はクラスタ2<クラスタ1<クラスタ3の順に上がっていき、表9と比較すると、スマートフォンへのアクセスが多い順に不安予測の精度が高くなっていることがわかる。

次に、Random Forestによって得られるジニ係数減少度が、SNS系アプリと娯楽系アプリに着目したもので高かった特徴上位7件を、表10に載せる。ジニ係数減少度は、

表 10 クラスタごとの特徴と不安増減の関係

Table 10 Relationship between Feature Values and Anxiety Change in Each Clusters.

特徴		共通	CL01	CL02	CL03	平均	標準偏差		
		SNS系アプリ	up	down	down	up	51.4	0.6	
暗い	静止・一定速度	SNS系アプリ		down	down	up	35.1	1.0	
暗い		SNS系アプリ		down	down	up	35.0	0.9	
	静止・一定速度	地面と平行	SNS系アプリ	down	down	down	up	34.0	0.8
	静止・一定速度		SNS系アプリ		down	down	up	33.9	1.2
暗い		地面と平行	SNS系アプリ	down	down	down	up	33.8	0.9
		地面と平行	SNS系アプリ	down	down	down	up	33.4	1.0
暗い	静止・一定速度		娯楽系アプリ	up		down	up	20.1	0.7
暗い			娯楽系アプリ	up		down	up	20.0	0.6
	静止・一定速度				down	up	19.6	0.7	
		地面と平行	娯楽系アプリ			down	up	19.3	0.6
	静止・一定速度	地面と平行	娯楽系アプリ	up		down	up	18.8	0.7
暗い		地面と平行	娯楽系アプリ	up		down	up	18.7	0.7
			娯楽系アプリ	up	down		up	16.4	0.4

特徴の重要度を表しており、この値が大きいほど不安変化に大きく関係のある特徴であることを表している。

表の左側は、組み合わせた特徴を、平均と標準偏差は、共通モデルにおけるジニ係数減少度の平均と標準偏差を表している。表の「共通/CL01/CL02/CL03」は、全員共通モデル、クラスタ 1,2,3 のモデルにおいて、その特徴が不安度の増と減どちらに現れるのか示している。たとえば、共通の「暗い」は「up」となっているが、これは暗いところでのスマートフォン操作時間が多いほど、不安度が上がる傾向にあることを意味している。算出方法としては、全サンプルを「STAI スコアが上がるサンプル」「下がるサンプル」の2つに分割したときに、各特徴量の平均を計算する。このとき、「上がるサンプル」のときの特徴量が有意に高ければ「up」、逆ならば「down」、差がなければ空白としている。

クラスタごとに見てみると、クラスタ 1・2 では、SNS系アプリと娯楽系アプリは、単独であっても、その他の特徴と組み合わせても、その傾向は「down」となっている。つまり、これらのアプリを、不安度が下がるときに多く使用している。一方で、クラスタ 3 では、傾向が全て「up」となっている。つまり、SNS系アプリと娯楽系アプリを、不安度が上がるときに多く使用している。つまり、普段からスマートフォンへ多くアクセスしているユーザは、アプリケーションへアクセスしているときに不安が上がる傾向にあり、あまりスマートフォンへアクセスしないユーザは、アプリケーションへアクセスしているときは不安が下がる傾向にあると言える。その理由として考えられるのは、普段からスマートフォンへ多くアクセスしているユーザは、不安を感じた時に、その逃避先としてアプリケーションへのアクセス行動をとるのに対し、普段あまりスマートフォンを触らないユーザは、不安を感じたときではなく、本当に必要で、スマートフォンへアクセスすることによって何らかの行動を起こそうとしているときにアプリケーションへアクセスするから、というアクセス理由の違いに起因するものではないかと推察できる。

7. 結論

本研究では、スマートフォンのセンサログ・アプリ履歴から、日常における無意識な不安の変化を予測することを目的とし、ログからカテゴリ量の特徴を設計し、ログによって得られたユーザのクラスタごとに予測モデルを構築することにより、78%の精度で予測が可能となった。また、日常的にスマートフォンへアクセスしているユーザの方が、不安予測精度が高いことが分かった。

今後は、アプリケーションのコンテンツにも踏み込んだ分析を行うことを検討したい。

参考文献

- [1] “Mind matters”, Article of *Nature*, Vol. 532, pp.6, 2016
- [2] <http://www.mhlw.go.jp/kokoro/know/symptom2.html>
- [3] 貝谷 久宣: “うつ病周辺での「心」の病気アラカルト-不安障害,” *こころのサポート*, Vol. 1, No. 1, pp. 24-28, 2010.
- [4] 貝谷 久宣, 土田 英人, 巢山 晴菜, 兼子 唯: “不安障害研究鳥瞰-最近の知見と展望-,” *不安障害研究*, Vol. 4, No. 1, pp. 20-36, 2013.
- [5] 高橋 利果: “メンタルヘルスケアの基礎知識-マネジメント・企業編-,” *中小企業診断協会 心の病に負けないヒトと企業のつくり方*, pp.12-17, 2011.
- [6] 西村 千秋: “バイオフィードバック学会のめざすところ”, *日本バイオフィードバック学会 横幹連合ニュースレター*, Vol. 2, No. 1, pp.49-51, 2009.
- [7] Mai-Ly N. Steers, Robert E. Wickham, and Linda K. Actielli: “SEEING EVERYONE ELSE’S HIGHLIGHT REELS: HOW FACEBOOK USAGE IS LINKED TO DEPRESSIVE SYMPTOMS,” *Journal of Social and Clinical Psychology*, Vol. 33, No. 8, pp. 701-731, 2014.
- [8] Agnes Gruenerbl, Venet Osmani, Gernot Bahle, Jose C. Carrasco, Stefan Oehler, Oscar Mayora, Christian Haring, and Paul Lukowicz: “Using Smartphone mobility traces for the diagnosis of depressive and manic episodes in bipolar patients,” *Proceedings of the 5th Augmented Human International Conference*, No. 38, 2014.
- [9] Luca Canzian, and Micro Musolesi: “Trajectories of Depression: Unobtrusive Monitoring of Depressive States by means of Smartphone Mobility Traces Analysis,” *Proceedings of the 2015 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp. 1293-1304, 2015.
- [10] Russell B. Clayton, Glenn Leshner, and Anthony Almond: “The Extended iSelf: The Impact of iPhone Separation on Cognition Emotion, and Physiology,” *Journal of COMPUTER-MEDIATED COMMUNICATION*, Vol. 20, No. 2, pp. 119-135, 2015.
- [11] Spielberger,: “Manual for the State-Trait Anxiety Inventory,” *Palo Alto, CA: Consulting Psychologists Press*, 2014.