

スマートフォンのセンサログとアプリ履歴を用いた不安度の予測

伊藤拓^{†1} 深澤佑介^{†2} 沖村幸^{†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使用履歴を用いて、不安度の増減予測を行った。予測にあたり、不安状態がスマートフォンの操作に反映されるような特徴量を設計した。具体的には、1日に受けた光刺激の強さ、スマートフォンへのアクセス時間、アプリの利用回数といった不安状態と関係のある症状として現れやすいスマートフォンの特徴量を考案した。重回帰分析により不安度の上下を予測し、平均で9割ほどの精度を得られた。また、重回帰分析の回帰係数を比較することで、提案した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, センサログ, アプリ履歴, 重回帰分析

Nonpathological Anxiety Prediction Using Both Sensor Logs and Application History of Smartphones

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

Keywords: mental health, anxiety, smartphone, sensor logs, application history, multiple regression analysis

1. はじめに

近年、メンタルヘルスへの関心が高まっている。2015年にはイギリスが持続可能な開発目標にメンタルヘルスについての記述を加えたほか、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]。日本では2015年12月から、50名以上の労働者を抱える事業所では、労働者のストレスチェックが義務化されている[2]。労働者の精神状態を維持することが、重要視されている。しかし現状では、ストレスは年に1回もしくは2回の自身によるアンケート調査によって行われており、労働者の負担になるほか、連続的な評価ができないという問題がある。

負担の少ない連続的な精神状態の評価を行うために、スマートフォンを利用した精神状態推定の研究がなされている。スマートフォンは、個人が所有するものであり、常に身につけていることが多いため、搭載されているセンサを用いて精神状態を推定するために有用である。こうした性質からWHOは、メンタルヘルスに関する計画の中で、携帯電話の技術を通じた自己管理を促進すべきであるとしており[3]、多くの研究がなされている。具体的には、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/非うつを判定する研究[4]や、スマートフォンのGPSデータから得られた位置情報を用いてうつ度がその人の平均と比べて

高いかどうかを判定する研究[5]、電話・メールの通信相手からストレス状態を推定する研究[6]が存在する。また、センサだけではなくスマートフォンのアプリ履歴に着目した研究もされており、Facebookに多くの時間を割いている人はうつになりやすいという研究[7]が存在する。上記の研究においては、得られたデータから特徴量を抽出して精神状態を推定する方法がとられている。特徴量抽出においては、推定する精神状態に関係する症状に応じて、それが日常におけるスマートフォンの利用に反映されやすい特徴量であることが求められており、課題として残されている。

本研究では、複数存在する精神疾患の中でも、不安に着目して実験を行う。理由としては、不安障害は早期発症であり併発症の頻度が高い、引き起こされる併発症は重症かつ社会的障害が大きいという問題の重大性によるものである[8]。我々は、スマートフォンから得られる複数のセンサログ・アプリ履歴から、不安と大きく関係があると考えられる複数の特徴量を提案し、特徴量の学習によって次の日の不安度を予測することを目指す。

2. 関連研究

本章では、スマートフォンのセンサログやアプリ履歴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[4]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[5]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、旋

^{†1} 東京大学
The University of Tokyo

^{†2} (株)NTT DOCOMO
NTT DOCOMO, Inc.

^{†3} 慶應大学
Keio University

^{†4} 国立精神・神経医療研究センター
National Center of Neurology and Psychiatry

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。電話とメールの送信履歴からストレス度を判定する研究[6]では、学生に対して試験前などストレスの強い期間は、そうでないときと比べて電話やメールを同じ人に集中してしやすいという報告がされている。SMSの利用履歴から、スマートフォンによるコミュニケーションの多様性を特徴量として抽出した、同様の研究[9]も存在する。また、スマートフォンの音声センサに着目し、声の変化を捉えることで、8割の精度でストレス状態を判別した研究[10]もなされている。

スマートフォンを用いた研究では、搭載されたセンサを用いるだけでなく、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がなされている。スマートフォン分離不安障害を調べた研究[11]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が落ち、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いと述べられている。

スマートフォンで取得できるデータは、上記の研究のように特徴量化を行ったうえで精神状態との関係を調べるという手順が一般的である。その上でどのような特徴量を抽出するかが重要であるが、今回焦点を当てる不安については、光が異常に眩しく感じるために明るい場所にいることを避ける、スマートフォンへの操作がやめられなくなるために、歩きスマホをよく行う、アプリの起動回数が増えるなど複数の症状が想定される。このような、不安と関係があり、スマートフォンの操作に反映されるだろう特徴量を選択することが課題である。

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)[12]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。今回PHQではなくSTAIを指標とした理由は、PHQの対象がうつ病であり、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。今回研究で予測したい対象は、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。これは、不安度は相対的なものであり、不安度が上がるもしくは下がるという変化こそが知るべき情報であると考えたからである。

本報告では、数日分のセンサログ・アプリ履歴を用いて

予測を行うが、予測にあたって何日分のデータを入力すれば十分であるかは重要な要素である。したがって、実験においては1日分~7日分の7種類の入力データを用意し、何日分のデータを使えば予測精度が上がるのかを検証する。たとえば3月19日の不安度が前日と比べて上がったか下がったかを予測するのに、3月18日のセンサログ・アプリ履歴だけで十分なのか、3月17日・3月18日の2日分のデータが必要なのか、何日分のデータが必要なのかという問題を解く。本報告で扱う問題のイメージを図1に示す。




図1 不安度予測問題のイメージ

Figure 1 The Image of Anxiety Prediction Problem

予測精度の評価値としては、 F 値という指標を用いる。また、実際に抽出した特徴量のうち、全員に共通してどの特徴量が不安度の増減と強く関係しているのかについても評価を行う。評価方法については、第6章で詳しく述べる。

4. 提案手法

本章では、今回不安度の増減予測に使用する特徴量の提案について述べる。

使用したセンサは、加速度センサ・回転センサ・照明センサの3つであり、1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1秒ごとに記録している。これらのログデータからいくつかの特徴量を抽出し、特徴量同士を組み合わせることで新たな特徴量を計算している。

ここで、1日の中でログを記録した時間を、 $t=1,2,\dots,N$ として表す。なお、 N は1日の中でのログの総記録回数である。時間 t におけるセンサの値を、以下のように定義する。

加速度センサ (X 軸, Y 軸, Z 軸)	$A_t(x), A_t(y), A_t(z)$
回転センサ (X 軸, Y 軸, Z 軸)	$R_t(x), R_t(y), R_t(z)$
照明センサ	L_t
画面オンオフ	S_t

L_t は、スマートフォンを利用している環境の明るさであり、単位はルクス。 S_t は、1ならば画面がついており、0ならば画面が消えていることを表す。

1)1日の平均加速度 A_A

$$\frac{\sum_{t=1}^N \sqrt{A_t(x)^2 + A_t(y)^2 + A_t(z)^2}}{N}$$

2)1日の分散加速度 V_A

$$\frac{\sum_{t=1}^N (\sqrt{A_t(x)^2 + A_t(y)^2 + A_t(z)^2} - A_A)^2}{N}$$

3)1日の平均明るさ A_L

$$\frac{\sum_{t=1}^N L_t}{N}$$

4)1日の分散明るさ V_L

$$\frac{\sum_{t=1}^N (L_t - A_L)^2}{N}$$

5)明るさが300ルクス以内の時間割合 R_{LOWL}

$$\frac{\sum_{t=1}^N t(L_t < 300)}{N}$$

$t(L_t < 300)$ は、時刻 t のとき照明センサの値が300ルクス以内ならば1、それ以外ならば0を示す。

6)明るさが300~1000ルクスの時間割合 R_{MIDL}

$$\frac{\sum_{t=1}^N t(300 \leq L_t \leq 1000)}{N}$$

$t(300 \leq L_t \leq 1000)$ は、時刻 t のとき照明センサの値が300ルクス~1000ルクスならば1、それ以外ならば0を示す。

7)明るさが1000ルクス以内の時間割合 R_{HIGHL}

$$\frac{\sum_{t=1}^N t(1000 < L_t)}{N}$$

$t(1000 < L_t)$ は、時刻 t のとき照明センサの値が1000ルクス以上ならば1、それ以外ならば0を示す。

8)画面がオンになっている時間割合 S_s

$$\frac{\sum_{t=1}^N S_t}{N}$$

9)歩きスマホの割合 S_w

$$\frac{\sum_{t=1}^N t(S_t = 1 \text{ and } A_A > 1.0)}{N}$$

$t(S_t = 1 \text{ and } A_A > 1.0)$ は、時刻 t のときに、画面がオンになっていて加速度の大きさが 1.0 m/s^2 以上のときに1、それ以外ならば0を示す。これは、ある一定の加速度があり、画面がオンになっているならば、歩きスマホをしているのではないかという仮定による。

10)スマホへのアクセス割合 S_x

$$\frac{\sum_{t=1}^N t(S_t = 1 \text{ and } R_x > 0.1)}{N}$$

$t(S_t = 1 \text{ and } R_x > 0.1)$ は、時刻 t のときに、画面がオンになっていて x 軸方向の傾きが0.1以上のときに1、それ以外ならば0を示す。これは、前後方向に一定の傾きがあり、画面がオンになっているならば、スマホをアクセスしているのではないかという仮定による。

以下に述べる特徴量は、1つ1つのアプリについて1つずつ計算するものである。以下で、あるアプリ I の特徴量として述べているが、 I には LINE や Twitter など、各種アプリ名が入る。

11)あるアプリ I の1日の起動時間 I_h

$$\frac{\sum_{t=1}^N t(I_{t-1} = 0 \text{ and } I_t = 1)}{N}$$

I_t は、時刻 t においてアプリ I が起動しているならば1、起動していなければ0を示す。 $t(I_{t-1} = 0 \text{ and } I_t = 1)$ は、時刻 $t-1$ においてアプリが起動しておらず、時刻 t において起動しているときに1、それ以外るときに0を示す。すなわち、アプリを起動した回数を表す。

12)あるアプリ I の1時間あたりの最大起動時間 I_m

$$\frac{\max_{(h=1,2,3,\dots,24)} \sum_{t=1}^{N_h} t(I_{t-1} = 0 \text{ and } I_t = 1)}{N}$$

上の式で、 h は24時間表記の時刻を表している。 N_h は、時間 h におけるログの記録回数を表している。すなわち、1日を24時間に区切った時に、もっとも起動回数の多い時刻の起動回数を表している。これにより、1日の中で同じ起動回数であっても、1日を通じて回数が多いか、それとも特定の時間に集中して起動しているのかを区別できる。

13)あるアプリ I の平均継続使用時間 I_a

$$\frac{\sum_{t=1}^N I_t}{N}$$

14)あるアプリ I の標準偏差継続使用時間 I_s

$$\frac{\sum_{k=1}^{I_h} (I_{L_k} - I_a)^2}{N}$$

I_{L_k} は、一日の中で k 番目の利用時における継続使用時間を表している。

実験手順

本章では、第4章で提案した特徴量を用いて、実際に不安度の増減を予測するための実験手順について説明する。

4.1 予測手法と入力データ

今回は不安度の増減を予測するために、リッジ回帰とよばれる重回帰分析の1種である分析を行った。リッジ回帰は、正則化パラメータを考慮することによって各パラメータの絶対値が大きくなりすぎることを防ぎ、学習データに対して過学習が起きてしまうことを避ける効果がある。また、学習によって得られた回帰係数を見ることによって、どの特徴量が目的変数と強い関係を持つかを調べることができる。

入力データとしては、「ある日 X の目的変数(不安度増減+1か-1)、その前の期間($X-1 \sim X-N$)の説明変数を1サンプルとして、数日分」である。 N の値が1から7まで動かし、実験協力者1人につき7種類の入力データを用意する。また、今回は全員分のデータをまとめて1人分のデータとして扱ったときに、他サンプルの不安度増減を予測できるかも調べるために、協力者全員のデータを1つにまとめたデータについても、7種類の入力データを用意する。ただし、関係の強い特徴量を調べる際は、全員共通のデータを用い

て調べる．全員共通データにおいては，共通して使用しているアプリが LINE のみであったため，上記特徴量においてアプリは LINE のみを採用する．また，人によって特徴量の値が全く異なるため，すべての特徴量について，協力者ごとに平均を 0 とする標準化を行ってからデータを統合する．

学習と検証の方法について説明する．本実験では，交差検証を用いる．数日分のデータを 3 つに分割し，2 つを学習用データ，もう 1 つを検証用データとする．学習データから回帰曲線を生成し，検証用データで精度を求める．次に違う 2 つの学習データから学習し，残った 1 つのデータで精度の検証を行う．こうして 3 回の学習-検証プロセスを行い，精度の平均を出すことによって，あるパラメータに対する全体の精度を求めることができる．この操作を複数のパラメータに対して行うことにより，最適なパラメータを見つけることができる．最適なパラメータを発見したら，それをもとに回帰曲線を生成し，各サンプルに対する目的変数の値を求める．リッジ回帰では出力される変数は実数値であるため，その値が正もしくは 0 ならば+1, 負ならば-1 を出力する．この過程で出力された予測値と，実測値を比較することで，ある実験協力者の，N 日分のデータを用いたときの不安度増減予測精度を求めることができる．これを N=1~7 の 7 セット，さらに実験協力者の人数+全員共通データの分を行い，評価する．

4.2 実験対象とアンケート項目

今回実験に協力してもらったのは，男女含む学生 7 名である(男性 5 名，女性 2 名，年齢は 22-23 歳)．STAI のアンケート結果と，センサログ・アプリ履歴を同時に保存・送信するアプリを開発し，実験協力者へ配布した．1 ヶ月間配布し，毎日 1 回 STAI のアンケートに答え，結果を送信するように伝えておいた．STAI の質問項目，および回答項目を以下に示す．

1. 気が落ち着いている
2. 安心している
3. 緊張している
4. くよくよしている
5. 気楽だ
6. 気が動転している
7. 何か悪いことが起こりはしないかと心配だ
8. 心が休まっている
9. 何か気がかりだ
10. 気持ちがよい
11. 自信がある
12. 神経質になっている
13. 気が落ち着かず，じっとしてられない
14. 気がピンと張りつめている
15. くつろいだ気持ちだ

16. 満ち足りた気分だ
17. 心配がある
18. 非常に興奮して，体が震えるような感じがする
19. 何かうれしい気分だ
20. 気分がよい

各設問に対して，

全くちがう/いくらか/まあそうだ/その通りだ

の 4 つから 1 つ選択する．各設問は，不安があることを示す不安存在項目，不安がないことを示す不安不在項目の 2 種類に分けられ，不安存在項目は，上の 4 つの回答に対して左から 1,2,3,4 のスコアが割り当てられ，不安不在項目は左から 4,3,2,1 のスコアが割り当てられる．このスコアを 20 問合計した値が，STAI スコアとなり，この点数が高いほどその人のその日の不安度が高いことを表す．しかし，問題設定の章でも記したとおり，スコア自体を予測することに意味はないため，前日と比較してスコアが上がったか下がったかを実験では予測する．

5. 評価

5.1 予測問題の評価指標

評価値としては，機械学習の分野でクラス分類の正しさとしてよく用いられている F 値[13]を用いる．F 値は，適合率と再現率という 2 つの指標の調和平均によって表される．また，F 値は，クラス判定の際，各クラスに対して算出され，全体としては各クラスの F 値の調和平均を求めることによって計算する．今回の問題では，ある日の不安度が+1 か-1 かを求める 2 クラス判定の問題であるから，+1 クラスの F 値，-1 クラスの F 値をそれぞれ求め，その調和平均によって全体の F 値を求める．+1 クラスの適合率，再現率は，R:予測値も実測値も+1 であったデータ数，N:予測値が+1 であったデータ数，C:実測値が+1 であったデータ数とする

$$(+1 \text{ クラスの適合率}) = \frac{R}{N}$$

$$(+1 \text{ クラスの再現率}) = \frac{R}{C}$$

$$(+1 \text{ クラスの適合率}) \tag{1}$$

$$= (\text{適合率と再現率の調和平均})$$

$$= \frac{2R}{(N+C)}$$

と定義される．これを-1 クラスについても同様に求め，全体の F 値を計算する．

5.2 回帰による予測の結果

実験協力者 7 名+全員共通データにおける，説明変数の日数と，F 値との関係を表したグラフおよび表を図 2 と表 1 に載せる．

グラフは，横軸が説明変数の日数，縦軸が F 値を表して

いる。F 値の定義上、適合率もしくは再現率のどちらかが 0 になると計算ができないため、そのようなケースでは欠損値として扱い、表では灰色で示している。

次に、実験協力者 7 名の F 値の平均値のグラフと表を図 3、表 2 に示す。




図 2 説明変数の日数と F 値の関係のグラフ

Figure 2 Graph of Relationship between the Number of Days of Explanatory Values and F-value

表 1 説明変数の日数と F 値の関係の表

Table 1 Table of Relationship between the Number of Days of Explanatory Values and F-value

実験協力者	1日分	2日分	3日分	4日分	5日分	6日分	7日分
A	0.34	0.34		0.88	0.92	1.00	0.64
B			0.92	1.00	1.00	1.00	1.00
C							0.80
D	0.89	0.94	0.83	0.94	0.94	0.94	1.00
E	0.59	0.89	0.94	1.00	1.00	0.83	0.83
F	1.00	1.00	1.00	0.94	1.00	1.00	1.00
G	0.47	0.81	0.68	1.00	1.00	1.00	1.00




図 3 説明変数の日数と F 値平均の関係のグラフ

Figure 3 Graph of Relationship between the Number of Days of Explanatory Values and the Average of F-value

表 2 説明変数の日数と F 値平均の関係の表

Table 2 Table of Relationship between the Number of Days of Explanatory Values and the Average of F-value

1日分	2日分	3日分	4日分	5日分	6日分	7日分
0.47	0.57	0.63	0.82	0.84	0.83	0.90

図 2 および表 1 を見ると、7 名で F 値はバラバラであるが、説明変数の日数が増えると F 値が上昇していくという共通の傾向があることが分かる。日数が増えると F 値が下

がる場合があるが、これは多重共線性によるもので、相関の強い説明変数が含まれることにより、回帰に影響を及ぼしたためであると考えられる。

F 値が定義できていない箇所は、予測がすべて+1、もしくは-1 など、十分な学習ができていないことを示す。協力者 C は 6 日分まではその状態であったが、7 日分考慮することによって予測が正しく行われるようになり、すべての協力者について F 値が 0.6 を上回っている。また、F 値の平均を見ると、4 日分考慮したときに 0.8 を越え、7 日分考慮することによって 0.9 の精度に達している。

次に、サンプル数を現在の 1 ヶ月から増やしたとき、F 値がどうなるのかについて考察する。3 ヶ月や半年といった長期間にわたる実験を行ったときには、F 値は下がると考えられる。理由としては、その人の精神状態とスマートフォンとの関わり方が常に一定ではない可能性が高いからである。たとえば、あるときには不安なときに LINE を多く利用する人が、別のあるときには不安なときに Facebook を多く利用するというように、不安とスマホ利用との関係性が移ろうことが起こりうる。特にセンサと比べてアプリの場合には頻繁に利用するアプリが変わるということがあるので、そのような場合長期間学習しても精度がかえって下がってしまうと推測できる。そのような場合には、できるだけ考慮する日数を長くとり、人のスマホ利用の揺らぎを吸収して学習する必要はないかと考えられる。

5.3 回帰係数による特徴量の評価

次に、個人ごとに得られた特徴量の回帰係数から、全体でどの特徴量が不安度の増減と関係が強いかを議論する。個人で得られた回帰係数を平均することによって、全体の平均回帰係数を求めることができる。

5.1 節で述べたように、全員共通して使用しているアプリが LINE のみであったため、今回比較する特徴量は、第 4 章で提案した 1)~10)と、LINE の 11)~14)である。さらに、それぞれについて 1 日前から 7 日前までの特徴量を使用しているため、 $14 \times 7 = 98$ 個の特徴量について、その回帰係数を比較する。回帰係数の絶対値上位 10 位を表 3 に示す。

表 3 の中で、生データに近い特徴量と属性がついているものは、平均明るさや分散明るさなど、特徴量抽出にあたってあまり恣意的な要素を含まない、比較的生データに近い特徴量であり、今回提案した特徴量と属性がついているものは、アプリの使用回数や照明の閾値による段階分けの割合など、今回我々が仮説に基づいて設定した特徴量である。表 3 の値は、求めた回帰係数に対し、1 番絶対値の大きかった特徴量の回帰係数を 1 として正規化している。2 つの属性について、正規化された回帰係数の絶対値の平均を比較した結果を表 4 に載せる。今回提案した特徴量が生データに近い特徴量よりも係数の絶対値が大きくなっており、今回提案した特徴量が妥当であることが確認できた。

表 3 特徴量同士の回帰係数の比較

Table 3 Comparison of regression coefficient between feature values

特徴量	正規化された回帰係数	属性
1日前LINE起動回数	1.00	今回提案した特徴量
3日前300-1000ルクス割合	-0.95	今回提案した特徴量
2日前画面オン割合	-0.92	生データに近い特徴量
6日前1000ルクス以上	0.89	今回提案した特徴量
5日前平均明るさ	0.89	生データに近い特徴量
4日前分散加速度	0.88	生データに近い特徴量
1日前LINE標準偏差使用時間	0.88	今回提案した特徴量
3日前分散加速度	0.87	生データに近い特徴量
7日前画面オン割合	0.86	生データに近い特徴量
6日前画面オン割合	-0.84	生データに近い特徴量
7日前歩きスマホ割合	0.84	今回提案した特徴量
7日前1000ルクス以上割合	-0.80	今回提案した特徴量
1日前分散明るさ	0.79	生データに近い特徴量
3日前300ルクス以内	0.78	今回提案した特徴量
4日前LINE平均時間	-0.78	今回提案した特徴量
4日前平均明るさ	0.76	生データに近い特徴量
7日前平均明るさ	0.76	生データに近い特徴量
6日前スマホアクセス割合	-0.75	今回提案した特徴量
7日前300-1000ルクス割合	0.73	今回提案した特徴量
5日前300ルクス以内	-0.72	今回提案した特徴量

表 4 属性同士の回帰係数の平均比較

Table 4 Comparison of average of regression coefficient between attributes

属性	正規化された回帰係数の平均
生データに近い特徴量	0.88±0.02
今回提案した特徴量	0.93±0.05

6. 結論

本研究では、スマートフォンのセンサログとアプリ履歴を用いた不安度の予測に着目し、不安度を反映しやすいと考えられる特徴量を設計し、不安度を予測することを目的とした。

1日分～7日分までの特徴量を考慮した7種類のデータセットを実験協力者ごとに対して用意した。各データセットに対して、不安度を示す STAI アンケートのスコア増減を目的変数とする重回帰分析を行うことで、精度の検証を行った。その結果、どの協力者についても考慮する日数が増えるごとに精度が向上することが分かり、学習が困難であった協力者についても、7日分考慮することで0.8程度の精度を得ることができた。個人ごとの精度平均を見てみると、7日分考慮したときに0.9の精度が得られた。

また、重回帰分析の係数について、全体で平均した値を比較することによって、どの特徴量が不安度と強い関係があるかを調べ、提案した特徴量の妥当性を確認した。

本研究では、データサンプルが各協力者に対して1ヶ月であったために最大で7日分までしか考慮することができなかったという点、実験協力者が7名であるために全体で共通の知見を得たという保証を得るためには人数が少ないという点など、データ数に関する問題が残っている。また、全体で共通の予測モデルを構築する際、全員が使っているアプリがLINEのみであったために、共通モデルではアプ

リの特徴量としてLINEのみを用いたが、アプリに関する特徴量をもっと増やすことによって、新しい共通因子を見つけることができる可能性が高い。その場合、使っている人がいないアプリの場合もあるので、たとえばTwitterとFacebookを同じSNS系としてまとめるなど、複数のアプリを分類化することによって、共通モデルの特徴量の数を増やすことを考えたい。そのために、実験協力者が使っているアプリに着目し、どのような分類を行えばより高精度なモデルを構築することができるかを検討することを今後の課題としたい。

参考文献

- [1] “Mind matters”, Article of *Nature*, Vol. 532, pp.6, 2016
- [2] <http://www.armg.jp/mhlw/>
- [3] E. Anthes, “Mental health: There’s an app for that”, *Nature*, Vol. 532, pp.20, 2016.
- [4] A. Gruenerbl, et al. “Using smart phone mobility traces for the diagnosis of depressive and manic episodes in bipolar patients,” *Proc. of AH’14*, vol. 38, 2014.
- [5] L. Canzian, et al. “Trajectories of Depression: Unobtrusive Monitoring of Depressive States by means of Smartphone Mobility Traces Analysis,” *Proc. of ACM Ubicomp’15*, pp.1293-1304, 2015
- [6] G.Bauer, et al. “Can Smartphones Detect Stress-Related Changes in the Behaviour of Individuals?,” *Proc. of PERCOM Workshops*, pp.423-426, 2012.
- [7] M.N. Steers et al. “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] 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.
- [9] A. Madan, M. Cebrian, D. Lazer, and A. Pentlang: “Social sensing for epidemiological behavior change”, *Proc. of ACM Ubicomp’10*, pp.291-300, 2010.
- [10] H. Lu, D. Frauendorfer, M. Rabbi, M. Mast, G. Chittaranjan, A. Campbell, D. Gatica-Perez, and T. Choudhury: “Stresssense: Detecting stress in unconstrained acoustic environments using smartphones”, *Proc. of ACM Ubicomp’12*, pp.351-360, 2012.
- [11] B. Clayton, G. Leshner, and A. 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.
- [12] *State-Trait Anxiety Inventory*.
<http://www.saccess55.co.jp/kobetu/detail/stai.html>
- [13] D. Lewis, and R. Tong: “Text Filtering in MUC-3 and MUC-4”, *Proc. of MUC-4*, pp. 51-66, 1992.