Study on the intelligent smartphone for improvement of usability and users' behavior

メタデータ	言語: jpn 出版者: 公開日: 2017-10-05 キーワード (Ja): キーワード (En): 作成者: メールアドレス: 所属:
URL	http://hdl.handle.net/2297/43867

This work is licensed under a Creative Commons Attribution-NonCommercial-ShareAlike 3.0 International License.



博　士　論　文

操作性や利用者行動改善のための インテリジェントスマートフォン に関する研究

金沢大学大学院 自然科学研究科

電子情報科学専攻

知能情報・数理 講座

学　籍　番　号　1323112005

氏　　名　長谷川　達人

主任指導教官氏名　木村　春彦

提　出　年　月　平成27年7月

目 次

第 1 章　序論 **1**

第 2 章　近接センサによるスマートフォンの画面ロック手法 **3**

2.1　ロック手法 3

2.1.1　従来のロック手法 3

2.1.2　近接センサを用いたロック手法 4

2.2　近接ロックの改良 4

2.2.1　動作中画面との関連性 5

2.2.2　動作ログを用いた誤判断率改善手法 7

2.2.3　Naive Bayes による学習 7

2.3　評価 9

2.3.1　評価指標 9

2.3.2　実験結果 9

2.4　おわりに 10

2.4.1　まとめ 10

2.4.2　今後の課題 11

第 3 章　定期行動を学習するスマートフォンの音量自動設定手法 **12**

3.1　スマートフォンの音量設定 12

3.2　関連研究 14

3.2.1 ライフログ 14
3.2.2 マナーモードの自動切り替え 15
3.2.3 コンテキストアウェアネス 17
3.3 提案手法 17
3.3.1 アプリ音量の自動設定 17
3.3.2 前処理 19
3.3.3 学習データ 22
3.4 評価実験 1 22
3.4.1 識別手法 24
3.4.2 評価基準 25
3.4.3 実験結果 26
3.4.4 評価実験 1 の残課題と発展 27
3.5 評価実験 2 27
3.5.1 提案手法の修正 27
3.5.2 実験概要 29
3.5.3 考察 1（本研究の対象となる利用者の比率） 30
3.5.4 考察 2（マナーモード設定と曜日・時刻の関係性） 30
3.5.5 考察 3（アプリ音量とアプリの種類の関係性） 33
3.5.6 考察 4（修正した提案手法の有効性） 35
3.6 おわりに 39

第 4 章 スマートフォンの所在状況推定システム **41**

4.1 はじめに 41
4.2 提案手法 43
4.2.1 State Magic 43

4.2.2 特徴ベクトルの生成 44
4.2.3 重力加速度成分と加速度成分 45
4.2.4 特徴量 46
4.3 評価実験と考察 48
4.3.1 実験概要 48
4.3.2 評価指標 49
4.3.3 新規特徴量による精度変化の考察 50
4.3.4 利用者の動作に対する頑健性の考察 51
4.3.5 6 状態識別課題における推定精度の考察 53
4.4 おわりに 53

第 5 章 子供のスマートフォン依存を抑止する画面ロックアプリケーション 55

5.1 はじめに 55
5.2 関連動向 56
5.3 提案手法 57
5.3.1 利用者層の定義 58
5.3.2 システム概要 58
5.3.3 関連製品 59
5.3.4 利用シーンの提案 62
5.3.5 期待される効果 63
5.4 評価と考察 64
5.4.1 評価アンケート 64
5.4.2 利用者属性に関する分析 64
5.4.3 TIMER LOCK の効果 66
5.5 まとめ 69

第 6 章　結論 **74**

謝辞 **77**

参考文献 **79**

.1　付録 85

図 目 次

2.1 近接ロック動作イメージ 5

2.2 誤判断パターン例 5

2.3 Sensitivity，Specificity，Accuracy の比較 10

3.1 事前設定条件によるマナーモード自動切り替え 15

3.2 ライフログの検出と利用者サポートへの応用 18

3.3 システム構成図 19

3.4 GPS 異常値，欠損値の補完 21

3.5 本システムで採用している木構造識別器の概要 24

3.6 利用者がアプリ音量を決定する際の思考フロー 29

3.7 一日に一回以上音量変更を行う確率のヒストグラム 31

3.8 時刻別の平均マナーモード設定時間の例 31

3.9 User1 の時刻・曜日別の平均マナーモード設定時間 31

3.10 User4 の時刻・曜日別の平均マナーモード設定時間 31

4.1 State Magic のシステム概要 42

4.2 センサー値の処理方法 43

4.3 Android における加速度センサの軸方向 46

4.4 スマートフォンの格納場所一覧 47

5.1 TIMER LOCK の動作フロー 60

5.2 TIMER LOCK 操作画面: (a) 無償版設定画面 (b) 有償版設定画面 (c) ロック中のホーム画面 61
5.3 導入者別の利用者年齢分布 65

表 目 次

2.1 画面ごとの誤判断率 6

2.2 評価指標の定義 9

3.1 Android と iOS におけるマナーモード設定と音量設定の関係 14

3.2 蓄積するデータの種類 20

3.3 データ取得タイミング 21

3.4 記録データサンプル 23

3.5 評価指標 25

3.6 提案手法とマナーモード連動手法における予測精度比較 26

3.7 取得する情報の一覧 29

3.8 アプリ毎のアプリ音量をオンで利用する比率の例 34

3.9 被験者 107 名の平均推定精度 36

3.10 代表的な利用者に対する推定精度 36

3.11 U1 の初期音量と正解音量のクロス表 37

3.12 U1 のマナーモードと正解音量のクロス表 37

3.13 U1 の SVM 予測結果と正解音量のクロス表 37

3.14 U2 の初期音量と正解音量のクロス表 37

3.15 U2 のマナーモードと正解音量のクロス表 37

3.16 U2 の RF 予測結果と正解音量のクロス表 37

3.17 U3 の初期音量と正解音量のクロス表 38

3.18 U3 のマナーモードと正解音量のクロス表 38
3.19 U3 の RF 予測結果と正解音量のクロス表 38

4.1 実験時の作業パターン一覧 48
4.2 評価指標の定義 49
4.3 全特徴量を利用したデータセット A と加速度のみを利用したデータセット B における LOSO-CV の F 値比較 51
4.4 提案手法採用時の利用者状態別推定精度 52
4.5 提案手法による 6 状態識別結果 53

5.1 TIMER LOCK の利用者層と特徴 57
5.2 アンケートの内容 71
5.3 利用者層別の回答者数と平均年齢 72
5.4 利用者層別の Q11（スマホを使い始めて，健康や精神的な弊害が出たと思いますか）の “はい” の回答率 72
5.5 利用者層別の Q7（TIMER LOCK を利用してみてよかったと思いますか）の “はい” の回答率 72
5.6 利用者属性別の TIMER LOCK 導入前後でスマートフォンの利用時間が減少した回答者の比率 73
5.7 TIMER LOCK 導入後の実際の行動に関するロック中の行動 [回答者数（比率）] 73
5.8 TIMER LOCK 導入後の一日の勉強時間の増加 [回答者数（比率）] 73

1 1 フレームから抽出する特徴ベクトル 85

第 1 章

序論

総務省の携帯電話の利用率に関する調査 [1] によると，2012 年の調査段階において，日本の総人口に対する携帯電話契約比率がついに 100%を超過した．中でもスマートフォンのシェアは国内外問わず急速に拡大しており [2]，日常生活をサポートする身近な情報機器となっている．スマートフォンは通話やメール，カメラ，ゲーム，音楽プレイヤー，カレンダー，アラームなど様々な機能があり，小型の PC と同程度の性能を備えている．

一般的に Android スマートフォンでは，照度センサやマイク，加速度センサ，ジャイロスコープ，地磁気センサなど多くのセンサを搭載している．また，利用者が常に持ち歩き，PC と同程度の処理能力を備えていることから，ライフログを記録することに適している．ライフログとはライフとログを組み合わせた言葉である．本研究ではライフログとは個人の行動や情報などを記録したものと定義して利用する．ライフログアプリケーションの例として，堀ら [3] や Sellen[4] らは，利用者の思い出やイベント，経験を動画として記録するシステムを開発している．それにより利用者は容易に生活の物語を動画として作成することができる．Jawbone 社の UP[1] は利用者の日々の運動や睡眠のパターンを，リストバンド型デバイスに搭載された加速度センサを用いて測定・記録している．利用者はそれらの記録された情報を健康維持に用いることができる．Adami ら [5] はライフログを用いて生活の質を向上させることができるシステムを開発している．ライフログは多くの場合利用者が手動で記録するが，通常は自動で記録できることが望ましい．この目的のため，利用者はカメラやセンサなど多くのデバイスを持ち運ぶ必要があるが，それは非常に手間である．それに対し，スマートフォンは負荷なく容易に様々なセンサを利用することができ，利用者らは常にそれを持ち歩くことからライフログを自動で記録することに適している．これ

[1][Up by Jawbone] https://jawbone.com/up

らの利用者情報からスマートフォンが自律的に利用者をサポートすることができれば，利用者はより快適に日常生活を送れることであろう．

本論文では，スマートフォンの標準搭載センサや機能から得られる多大なる情報を活用することで，スマートフォンの操作性改善や，さらには利用者自身の行動改善への応用を行う．まず，2 章では，近接センサを用いた自動画面ロックシステムを実現し，過去の誤動作を学習することでインテリジェントに誤動作防止を行うシステム [6] を説明する．次に，3 章では，スマートフォンのアプリ音量設定に着目し，日々の行動を学習しインテリジェントに自動でアプリ音量を切り替えるシステムを説明する．4 章では，コンシューマサポートに応用するための，スマートフォンの状況推定システム [7] を説明する．最後に 5 章では，子供のスマートフォン依存を改善するための画面ロックシステム [8] を説明する．

第 2章

近接センサによるスマートフォンの画面ロック手法

2.1　ロック手法

2.1.1　従来のロック手法

スマートフォンの画面ロック手法は現在標準で以下の２つの方法がある．

方法１：電源ボタンを押すことによる**手動ロック**
方法２：タイムアウトによる**時間ロック**

手動ロックは電源ボタンを押すことで画面ロックを行う方法である．時間ロックでは，利用者が端末設定された一定時間操作を行わないことでロック状態となる．利用者は２つの手法を併用し，ロックを意識しない利用者は方法２のみを用いることが多い．しかし，時間ロックだけでは電池の消耗を早めるだけでなく，利用者が端末から目を話した隙に他者に個人情報を盗み見られるリスクが高まる．したがって，端末の利用後は電源ボタンを押下してロック状態にしておくことが理想である．ただ，電源ボタンを押す動作は利用者の手間であり，さらに端末によっては押し辛い場所に電源ボタンがあることから，利用者により使いやすいロック手法の提案が必要とされる．

2.1.2　近接センサを用いたロック手法

本章では近接センサを用いる手法（近接ロック）を提案する．近接センサは多くのスマートフォンに標準搭載されている制御機器であり，端末上部のスピーカー横に搭載されていることが多い．近接センサは何かに覆われている際に反応するため，センサが反応するということは利用者は画面を見ていない可能性が高いと推測できる．近接ロックを実現することで，端末をポケットに入れた時，机に裏向きで置いた時，手をかざした時やカバーをした時（図 2.1）など様々なシーンで端末が自動的にロックされるような体感をえることができる．近接ロックは利用者の操作の負荷を軽減するだけでなく，他者からの盗み見防止の観点からセキュリティ向上にもつながる．

近接ロックを実現し利用した結果から，利点と欠点を従来のロック手法と比較する．利点はロックが容易になる点と，ロック忘れが減る点である．電源ボタンを押下することに比べ，ポケットに入れる，センサに手をかざすなどの常日頃から行う動作で意識することなく容易にロックができる．欠点は電池消費が少々増える点と，誤判断が起こりやすいという点である．近接ロックは近接センサを動作させるため何も使っていない状態より少々電力を消費する．また，近接ロックでは近接センサ反応時にロックを行うため，利用者が意図しないタイミングで近接センサが何に触れてロックされてしまうことがある（近接ロックの誤判断）．誤判断の動作パターンは例えば図 2.2 が考えられる．

(a) 大きく指を滑らせる場合

(b) 端末を横向きにして操作する場合

(c) センサに接触しやすい状態で利用する場合

2.2　近接ロックの改良

既存のアプリケーションとして近接オートロック [1] がある．これは誤判断の対策として，ディレイ（数秒間継続して近接反応がある場合ロックする）などの手法を用いている．ディレイは誤判断率を低下させる可能性はあるが操作性は低下する．例えば即座にロックしたい場合でも必ず数秒間継続して近接センサに触れなければロックできない．本研究では過

[1][近接オートロック] https://play.google.com/store/apps/details?id=com.nuts.autolock



図 2.1: 近接ロック動作イメージ

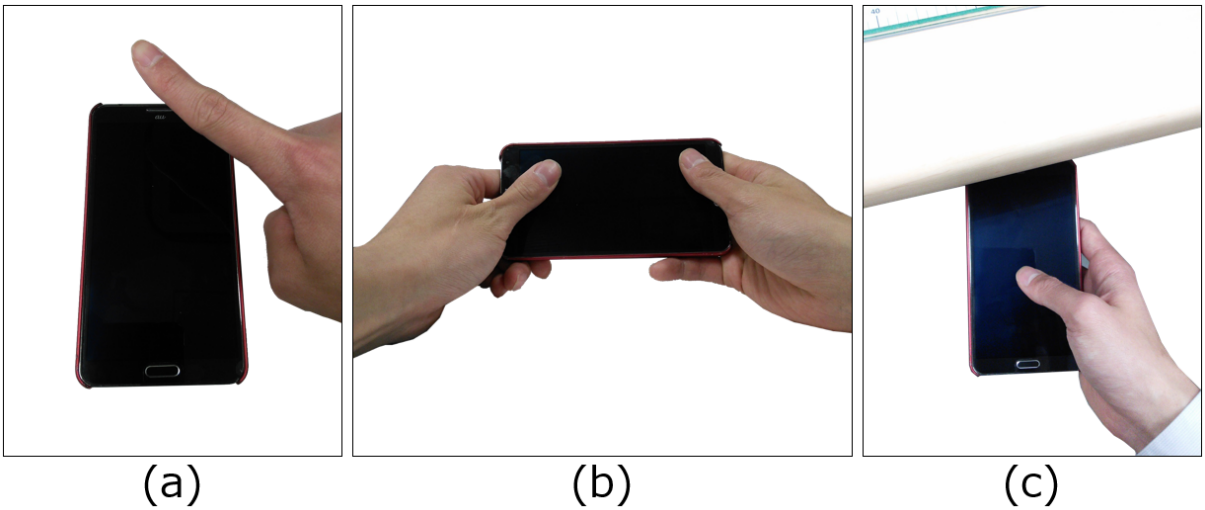


図 2.2: 誤判断パターン例

去の動作ログから利用者が端末を利用中かどうかを学習し，近接反応時にロック判定を行う手法を提案し，操作性を低下させず誤判断率を低下させる．

2.2.1　動作中画面との関連性

図 2.2(a)，(b) より誤判断は動作中の画面に相関がある可能性を考え，とある被験者一名の動作ログを 12 日間記録し表 2.1 にデータをまとめた．動作ログは近接センサ反応時に，動作中のアプリケーション画面と，近接ロックが正常判断であるか誤判断であるかの記録とする．誤判断の判定に関しては，近接ロック発生後即座（5 秒以内）に画面の再点灯が行われた場合は利用者が意図しないタイミングで近接ロックが反応したものと仮定して誤

表 2.1: 画面ごとの誤判断率

動作中の画面名	ロック回数	失敗回数	誤判断率
ナビ	7	7	100.0%
ブラウザタブ画面	7	7	100.0%
ジョブマネージャ	3	3	100.0%
着信歴	1	1	100.0%
クイック検索	1	1	100.0%
パズドラ	354	271	76.6%
ブラウザ	134	91	67.9%
Twitter	16	9	56.3%
緊急ダイアル	11	6	54.5%
電話帳	2	1	50.0%
フェイスブック	2	1	50.0%
LINE	39	17	43.6%
ホーム	547	165	30.2%
電話	37	8	21.6%
通話中	26	1	3.8%
その他	5	0	0.0%
全画面合計	1192	589	49.4%

判断とする．例えば，ゲームで遊んでいた際に意図せず近接センサに触れロックされたが，即座に画面を再点灯しゲームを再開した場合などが誤判断となる．なお，5 秒という数値は経験則から仮定している．

表 2.1 より動作中の画面によって，近接センサ誤判断の起こりやすさに傾向があることがわかる．例えば，ナビであれば 7 回のロック動作のうち 7 回が誤判断であることから，ナビ利用時には何らかの動作を行う際に，意図せず近接センサに触れていることが推測できる．

2.2.2　動作ログを用いた誤判断率改善手法

誤判断率を低下させるため，過去の動作ログを学習し近接ロックを行うタイミングでロックの可否を判断する手法を提案する．動作ログは動作中の画面と画面表示の向きの情報を利用する．画面表示の向きに関しては図 2.2(b) より動作中の画面同様，誤判断に影響があると考えられることから追加するものとした．動作ログの取得タイミングは近接センサ反応時とする．誤判断の判定に関しては近接ロック発生後即座（5 秒以内）に画面の再点灯が行われた場合と，見過ごしも誤判断として記録を行う．見過ごしとは「本アプリケーションがロックしないと判断したが，本来利用者がロックしたかった場合」のことと定義する．近接センサーが反応したタイミングから，画面が自動で消えるまでの間（2.1.1 節の時間ロックにて利用者の設定しているタイムアウト時間以内）にロックが行われた場合に見過ごしと判定する．例えば，タイムアウト時間を 1 分に設定している利用者が，意図して近接センサに触ったが近接ロックされなかったので，1 分以内に端末標準の手動ロックもしくは時間ロックを行った場合を見過ごしとして誤判断に含めている．

2.2.3　Naive Bayes による学習

動作ログの学習には Naive Bayes [9] [10] を用いる．モバイル端末上での実装のため分類精度が高いことに加え，リアルタイム処理のための処理速度が実現できること，電池消費量を抑えるため計算量が少ないことを加味した．

Naive Bayes

Naive Bayes は事象の事後確率を用いてカテゴリ分類を行う手法である．属性 $\boldsymbol{D}$ からカテゴリ $\boldsymbol{C}$ に分類する場合，事後確率は以下の式を用いて計算する．

$$P(\boldsymbol{C}|\boldsymbol{D}) = \frac{P(\boldsymbol{C})P(\boldsymbol{D}|\boldsymbol{C})}{P(\boldsymbol{D})} \tag{2.1}$$

式 (2.1) の $P(\boldsymbol{C})$ は既知の学習データから導出する事前確率，$P(\boldsymbol{D}|\boldsymbol{C})$ は尤度である．本来属性間の独立性は容易に仮定できないが Naive Bayes ではあえて独立性を仮定することで次式が得られる．

$$P(\boldsymbol{D}|\boldsymbol{C}) \quad = \quad P(D_1, ..., D_n|\boldsymbol{C}) \approx \prod_{i=1}^{n} P(D_i|\boldsymbol{C}) \tag{2.2}$$

分類カテゴリを求めることが目的のため，最大事後確率（MAP) 推定にてカテゴリを推定する．MAP 推定では分母 $P(\boldsymbol{D})$ は $\boldsymbol{C}$ に依存しないことから，分母が最大となるカテゴリを選択する．実装上は式 (2.2) の積算でアンダーフローが起こりうるため，対数の加算として計算する．大小関係は対数をとることに影響はない．MAP 推定により推定されたカテゴリを C_{MAP} とすると，分類されるカテゴリは式 (2.1)，(2.2) より次式にて計算できる．

$$C_{MAP} \quad = \quad \arg\max_{\boldsymbol{C}} \{\log P(C) + \sum_{i=1}^{n} \log P(D_i|C)\} \tag{2.3}$$

Naive Bayes を用いた誤判断率の改善

誤判断率の改善に対して，カテゴリ $\boldsymbol{C}$ はロックを行うか否か，属性 $\boldsymbol{D}$ は利用者の動作であり，アプリ画面と画面の向きとなる．近接反応時に最適なカテゴリ $\boldsymbol{C}$ を判別する．

$\boldsymbol{C} = \{C_l|$ ロックする$, C_n|$ ロックしない $\}$

$\boldsymbol{D} = \{D_1|$ アプリ画面$, D_2|$ 画面の向き $\}$

$D_1 \in \boldsymbol{D_{p1}} = \{$ 全アプリ画面 $\}$

$D_2 \in \boldsymbol{D_{p2}} = \{$ 縦, 横 $\}$

$T(x)$ を x が発生した回数と定義すると，式 (2.3) の事前確率 $P(C)$ は，動作ログより次のように計算できる．

$$P(C = C_l) = \frac{T(C_l)}{\sum_{C' \in \boldsymbol{C}} T(C')} = \frac{\text{ロックした回数}}{\text{動作ログ数}} \tag{2.4}$$

尤度は属性毎の積で算出するため，動作ログに現れなかった属性が含まれた場合，尤度が 0 となり精度に大きく影響を与えてしまうことがある（ゼロ頻度問題）．これに対応するため加算スムージングを採用し，スムージングパラメータ α を適用すると尤度は次のように計算できる．

$$\prod_{i=1}^{n} P(D_i|C = C_l) = \prod_{i=1}^{n} \frac{T(C_l, D_i) + \alpha}{\sum_{D' \in \boldsymbol{D_{pi}}} T(C_l, D') + |D_{pi}|\alpha} \tag{2.5}$$

なお，今回 $\alpha = 1$ としている．

表 2.2: 評価指標の定義

（単位：回）		利用者の想定動作	
		ロックする	ロックしない
アプリの動作	ロックする	TP	FP
	ロックしない	FN	TN

2.3　評価

2.3.1　評価指標

実際の利用データを用いて誤判断率の評価を行う．本アプリケーションは現在 Android 端末にて実装後，GooglePlay[2] にて「マジック★スクリーン β 版」として公開し，動作ログと各手法による結果の記録を行っている．結果とは 1. 対策なし , 2. ディレイ（3 秒），3.Naive Bayes でのロックか否かの判断である．ディレイの設定秒数は既存のアプリケーションの標準設定を採用し 3 秒とした．分類精度の評価は一般的な分類器は Recall と Precision の調和平均である F 値で評価するが，本件では，利用者が想定しないタイミングでロックされてしまうと利用者の操作を邪魔してしまうことから，表 4.2 の TP と同様に TN も重要な評価尺度とし，Sensitivity($\frac{TP}{TP+FN}$)，Specificity($\frac{TN}{TN+FP}$)，Accuracy($\frac{TP+TN}{TP+TN+FP+FN}$) で評価を行う [11]．ここで TP は利用者がロックすると想定した時にロックした回数であり，同様に FP(ロックしない想定でロックした回数)，FN(ロックする想定でロックしなかった回数)，TN(ロックしない想定でロックしなかった回数) と定義している．

2.3.2　実験結果

利用データから誤判断率を集計したものを図 4.2 に示す．データは被験者 8 名が 7〜14 日間利用したものの平均値である．利用端末は 2013 年現在発売されている Android 端末の内，近接センサを搭載したものとしており，特に Galaxy S2, AQUOS PHONE f SH-13C にて動作確認を行っている．実験の結果，近接反応時に必ずロックする “対策なし” は当然 Sensitivity が 100%，Specificity が 0%となり，Accuracy は 38%となった．ディレイ（3 秒）では Sensitivity は 49%になるものの，Specificity が 77%に向上したことで，Accuracy

[2]GooglePlay: https://play.google.com/store

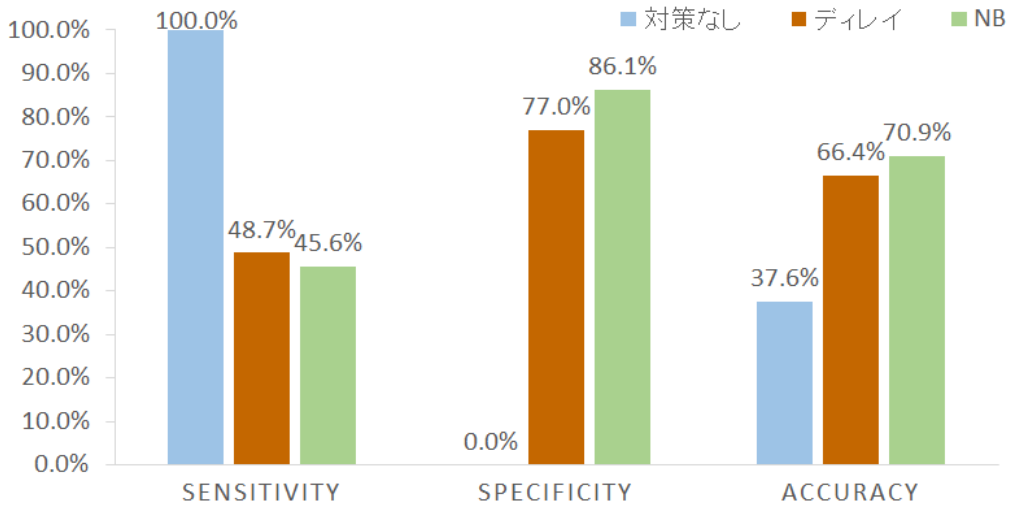


図 2.3: Sensitivity，Specificity，Accuracy の比較

が 66%に向上している．同様に提案手法である Naive Bayes でも Sensitivity は 46%となるものの，Specificity が 86%に大幅向上し，Accuracy が 71%とディレイよりもさらに向上している．Naive Bayes はディレイに比べても Accuracy を 5%向上させ，さらに意図したタイミングで即座に画面ロックが行えることから操作性も良い．

2.4　おわりに

2.4.1　まとめ

本研究では端末から得られる利用情報を基に携帯電話が自律的に利用者をサポートする第一段階として，利用者が意識せずとも端末が自動的にロック判断を行うアプリを Android スマートフォンにて開発を行った．近接ロック単体では誤判断が多かったことから，新しい誤判断率の低下手法を提案し，アプリ画面と近接ロックに相関がある可能性から Naive Bayes を用いた推定を行うことで誤判断率の改善を実現した．実際の利用実験の結果，既存の手法以上に誤判断率の改善が行えることを示し，さらには既存の手法よりも操作性が良いことから近接ロックをより実用的なものを実現した．

2.4.2　今後の課題

本研究では近接ロックをより実用的に改良したが，更なる課題として以下 2 点を記述する．

- ほかの利用情報を用いた精度改善：

時系列情報や，その他標準装備されている各種センサ値を利用することで，精度改善が行えると考えている．

- 電池消費量低下に対する取り組み：

近接ロックは無駄な画面点灯を減らすため，近接ロックに必要な電力を抑えることで省電力化に繋がると考えている．

第 3 章

定期行動を学習するスマートフォンの音量自動設定手法

3.1　スマートフォンの音量設定

スマートフォンは生活の中で非常に便利で有用なデバイスであるが，マナーや使い方が問題となることがある．例えば，公共の図書館で大音量でゲームをプレイしている人がいた場合，周囲の人らは迷惑に感じるだろう．図書館や映画館などの公共機関において，スマートフォンの音量設定は非常に重要な設定である．また，学校や会社などの社会環境においても，最適な音量設定は求められる．しかしながら現状では，利用者は手動で音量ボタンを押して音量を切り替える必要がある．そのため，一部の利用者は自分の意思で音量を変えなかったり，変えることを忘れてしまったりすることがある．これらは利用者の周囲に迷惑をかけるだけでなく，利用者自身のパフォーマンスにも悪影響を与える [12]．もし，利用者がマナーモードに設定することを忘れ，授業中に大きな音がなってしまった場合，授業を困惑させるだけでなく，授業を中断させることもある．利用者自身の評価に悪影響を与えることもある．仕事中の意図しない着信音は利用者の処理能力に悪影響を与え，ストレスや仕事の失敗を増加させるともいわれている [13].

音量設定は非常に重要な設定にもかかわらず，利用者は自身の状況に応じて手動で調整しなければならない．したがって，自動で音量を調整するシステムが望まれている．本研究では，利用者の過去の設定情報を機械学習にて学習し，Android スマートフォンにおけるアプリ音量のオンとオフを自動で切り替えるシステムを提案する．本研究がアプリ音量に着目した理由は 2 つある．1 つは着信音量がマナーモード設定と連動しているのに対し，

アプリ音量はマナーモード設定と連動していないことである．即ち，アプリ音量がゼロになっていなければ，スマートフォンがマナーモードに設定されていたとしても音が鳴ってしまう．2 つ目はマナーモードは変更しないがアプリ音量を定期的に変更する利用者層が存在することである．実験にて，9 人中 5 人の利用者が定期的にアプリ音量を切り替えていたが，マナーモードを定期的に切り替えていたのはただ 1 人であった．被験者数が多くないため，必ずしもスマートフォン利用者全体がマナーモード設定を定期的に切り替えていないとはいえないが，マナーモード設定を市内利用者が定期的にアプリ音量を切り替えている場合があることがわかる．本研究では，スマートフォンの音量設定に着目し，日々の利用者の音量設定パターンを学習し，インテリジェントに最適なアプリ音量を調整するシステムを開発する．本システムは Android スマートフォンのバックグラウンドにて定期的に操作ログを記録し，それらのログを学習する．使用しているアプリを切り替えたタイミングで，最適なアプリ音量を推定し自動で切り替える．本研究の目的は不意な音による悪影響を防止することである．そのため，一般的にアプリ音量は 16 段階で設定できるが，本研究では基礎研究としてアプリ音量がオンかオフかという点を推定する．

スマートフォンにはマナーモード設定や，着信音量，アプリ音量など様々な種類の音量設定がある．一般的なスマートフォンはマナーモードに，サウンド，バイブレーション，サイレントなどの設定が可能である．バイブレートモードは着信時に音を鳴らさずバイブレートするモードである．サイレントモードはバイブレーションも着信音も鳴らない．着信音量は着信時の音量レベルのことであり，アプリ音量はゲームや動画，音楽などを利用する際の音量設定である．有名な OS 毎の設定は表 3.1 にまとめる．

マナーモード設定をサウンドに設定していた場合，着信やメールの受信時には着信音量によって音が変わるが，マナーモード設定をバイブレーションやサイレントにしていた場合，着信やメールの受信時には音が鳴らない．したがって，着信音量はマナーモード設定に応じて変わる．一方，ゲームや動画などのアプリは，バイブレーションやサイレントに設定していようとも，アプリ音量に応じて音がなる．本研究ではこれらの問題を改善する目的も含めて，アプリ音量の自動設定に取り組む．

表 3.1: Android と iOS におけるマナーモード設定と音量設定の関係

	Android		iOS	
	着信	アプリケーション	着信	アプリケーション
サウンドモード	○	○	○	○
マナーモード	×	○	×	○ ※1

○: 音が鳴る ×：音が鳴らない

※1: 使用中のアプリによって鳴るか鳴らないかが変わる

3.2　関連研究

マナーモードを自動で切り替える研究や，着信音による意図せぬ妨害を防止するシステムなども含め，関連する研究を調査した．

3.2.1　ライフログ

ライフログとは利用者の行動や情報を記録したものである．本研究では特にスマートフォンで観測したものとする．スマートフォンにてライフログを観測する研究は多い [14, 15, 16]．これらの研究ではシステムが利用者の動作状態を 3 軸加速度センサの値を解析し分類することで記録している．小林ら [14] は歩行や走行，自転車走行，停止，車の運転，バスの乗車，電車の乗車などの様々な利用者の移動方法を推定することに成功している．また，我々は Google の Android 上の行動認識 API を用いることで容易に知ることができる．これらの研究は利用者がどのように移動し，行動したのかということをライフログとして記録することを可能にする．その他の研究においても，様々な利用者のライフログ情報を記録することを可能としている．大内ら [17] は屋内の行動認識に着目し，掃除や歯磨きなどの行動識別を行っている．Chen ら [18] や Hao ら [19] はスマートフォンの 3 軸加速度センサ値を用いて利用者の睡眠間隔を推定している．これらのようにスマートフォンや各種センサを用いて，学習者の周囲環境を測定，識別する研究が盛んに行われている．本研究では，これらのように観測できる利用者の周囲環境と，日々の設定の組み合わせによる自動設定

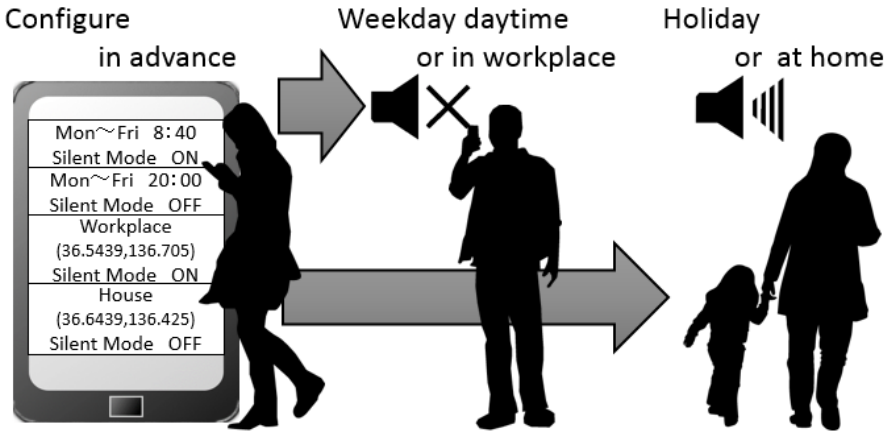


図 3.1: 事前設定条件によるマナーモード自動切り替え

を模索する．

3.2.2　マナーモードの自動切り替え

アプリ音量の自動設定に関して，マナーモード設定を自動化する研究を含め調査した．Android アプリとして Google Play[1] において公開されているアプリでは「オートマナー Plus+」[2] や「silence」[3] がある．目覚ましアラームを模した手法で，これらは図 3.1 のように予め利用者が設定しておいたタイミング（曜日・時間）をトリガーとしてマナーモードやアプリ音量を変更することができるアプリである．トリガーは時刻情報だけでなく，位置情報を利用したものもあり，予め利用者が設定しておいた領域内に入るとマナーモードの設定を変更する HexRinger[4] などのアプリも存在する．各アプリの DL 数から，自動で端末設定を変更するアプリの需要はあると考えられる．一方，現状ではこれらのアプリはトリガーや設定内容を利用者自身で指定する必要があり利用者に手間がかかるという課題がある．

トリガー設定以外の手法を用いた研究がいくつかある． 1 つは位置ベースの自動設定 HexRinger に Default Silent Zones という概念を提案するものである [20]．これは自分でトリガーとなる位置を設定しなくても，予め Default Silent Zones として定義されている病

[1][Google Play] https://play.google.com/store
[2][AutoManner+] https://play.google.com/store/apps/details?id=jp.chau2chaun2.mannerstimer
[3][Silence] https://play.google.com/store/apps/details?id=net.epsilonlabs.silence.ads
[4][HexRinger] https://play.google.com/store/apps/details?id=com.amay077.android.hexringer

院や大学のようなキーワードを含む場所にいる場合，自動でマナーモードを設定している．当研究では Default Silent Zones が予め定義されている分利用者がトリガーを設定する必要が減少する点は評価できるが，Default Silent Zones の定義を正確に行うのは難しい．また論文内にも記載されているように，大学と名のつく場所ではマナーモードと定義していた時に「大学前通り」なども対象としてしまう問題点がある．論文では Road を含む場合は除外しているようであるが,「大学前店」など様々なパターンをすべて回避できていないことや，会社などのマナーモードオンオフが混在しうる場所において効果を発揮できないという課題がある．

ほかにも，周囲の端末との協調を利用したオートマナー手法が提案されている [21]．当手法は自分のいる位置周辺にいる端末のマナーモードである比率を元に自身の端末のマナーモードを自動で設定する手法である．論文内ではサーバ上にデータを集約する手法と端末間で Bluetooth 通信を行う手法が紹介されている．はじめて行く映画館や公共機関において同様のアプリ利用者がいた場合に有用であると考えられる．ただ，論文内では多数のアプリ利用者が集まる場所において，協調的な自動設定が行えるという点を意識しており，人が少ない場所や利用者が習慣的に行っている設定に関しては触れられていない．また，前提として周りの人々が対象のシステムを導入している必要性があるが，これは現実的ではなく，導入コストが高いといえる．

その他，カレンダ情報を元にマナーモードの自動設定を行う手法も提案されている [22]．この手法は端末のカレンダに登録されているミーティングや昼食，買い物などの予定を元にマナーモードの自動設定を行っている．論文内では PDA 端末内で携帯電話のシミュレータを動作させ実験を行っており，カレンダ情報とマナーモードの関係性を実験している．結果，カレンダ情報からマナーモードを自動設定でき，利用者からは携帯端末に実装された際には利用したいとのアンケートは得られたが，利用者間で一貫性が薄かったとしている．この手法はカレンダの予定単位で細かくマナーモードを変更するような人が対象であり，かつカレンダ情報を事細かに入力でき，さらにそれを最新状態に保つことができる利用者には向いている．しかし，一般的な利用者としては負担が大きい．

3.2.3　コンテキストアウェアネス

コンテキストアウェアネスは本研究と関連する研究分野の一つであり，コンピュータが利用者の行動や周囲の環境，状況などを観測するというコンセプトや技術と定義されている．Abowd ら [23] によると，コンテキストアウェアネスでは，一般的に利用者の入力なしに自動でコンテキストを観測し適切なサービスを提供するシステムであるとしている．利用者のその時の状況や環境を観測し提供するため，利用者が日々持ち歩くモバイル端末と並列で研究されることが多い．従来は，モバイル端末におけるセンシング技術が発展していなかったことから，コンテキストを収集するためにコンピュータをほかのセンシングデバイスと接続して利用する必要があった [24, 25]．しかし，近年の Android や iPhone を代表とするスマートフォンは標準で様々なセンサを搭載しており，ほかのデバイスを用いずとも容易に周囲の情報を収集することが可能となった．

本研究では，利用者がアプリ音量の設定忘れの際に，周囲への迷惑や利用者自身の集中を妨げることを防止することを目的としている．したがって，我々はコンテキストアウェアな技術を応用し，周囲の状況から音量設定を自動化するシステムを開発する．上述したように，関連研究では様々なマナーモード自動化の研究がなされてはいるものの，ほとんどにおいて利用者は自身で時間や場所などの変更条件や，詳細なカレンダーを入力する必要があり手間である．それに対し，本研究ではスマートフォンで収集するコンテキストを学習し自動で音量設定を行うシステムを提案する．そのため利用者は事前に自身で変更条件などを入力する必要がない．さらに関連研究とは異なり，正しい音量設定の正解値を日々の利用者自身の設定から徐々に学習していく．したがって，利用者は正解データを予めシステムに教えておく必要もない．

3.3　提案手法

3.3.1　アプリ音量の自動設定

本研究では，スマートフォンから観測されるコンテキストを機械学習により学習し，自動で最適な音量を設定する手法を提案する．スマートフォンは常時利用者のコンテキストを観測し，利用者の特徴を学習する．そして，図 3.2 のように利用者の状況に応じた最適な音量を推定する．具体的には，学校では音量をオフに，自宅ではオンにして利用しているなど

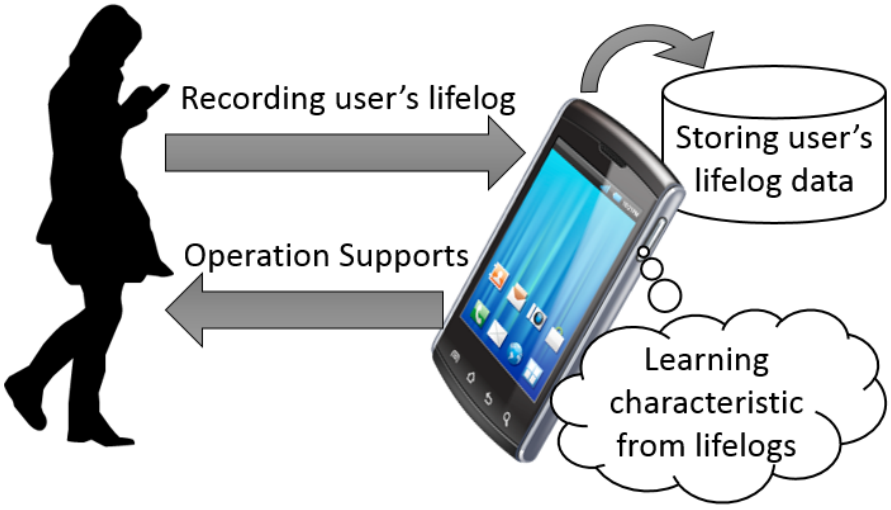


図 3.2: ライフログの検出と利用者サポートへの応用

の日々の週間を特徴として抽出し，自動で音量を設定する．本システムはバックグラウンドにて収集したコンテキストをもとに最適な音量を自動設定する．図 3.3 は本システムのシステム概要であり，本システムは Android の標準 API より SensorManager や AudioManager を通じでセンサ値を観測している．Android スマートフォンは大まかに分けて内部環境，外部環境，設定，時刻の情報を収集することができる．内部環境とはスマートフォンのソフトウェア的情報であり，表示しているアプリ名や着信履歴，Wi-Fi の接続履歴などの操作ログのことである．外部環境とは外的な情報であり，周囲の騒がしさや，位置情報，明るさ，利用者の動作などの利用者の外部の環境のことである．設定とはマナーモードやアプリ音量などスマートフォンの設定のことである．時刻とは，曜日や時間など，イベントが発生した時刻情報のことである．これらのコンテキストは内部のデータベースに記録される．

本システムはオープンソースのデータマイニングツールである Weka[26] を用いて，スマートフォンの画面がオフになったタイミングでコンテキストを学習する．そして，本システムは表示アプリが変更されたタイミングで最適な音量はオンかオフかを推定し，自動で設定する．画面がオンの時に学習を行うと，計算処理による負荷がかかってしまうことから，学習処理は画面がオフのタイミングで実施する．また，突然音量が変更されると利用者が困惑するであろうことから，音量の変更タイミングは利用しているアプリが切り替わったタイミングとしている．

本システムはバックグラウンドで定期的に学習データを蓄積している．本システムで今回

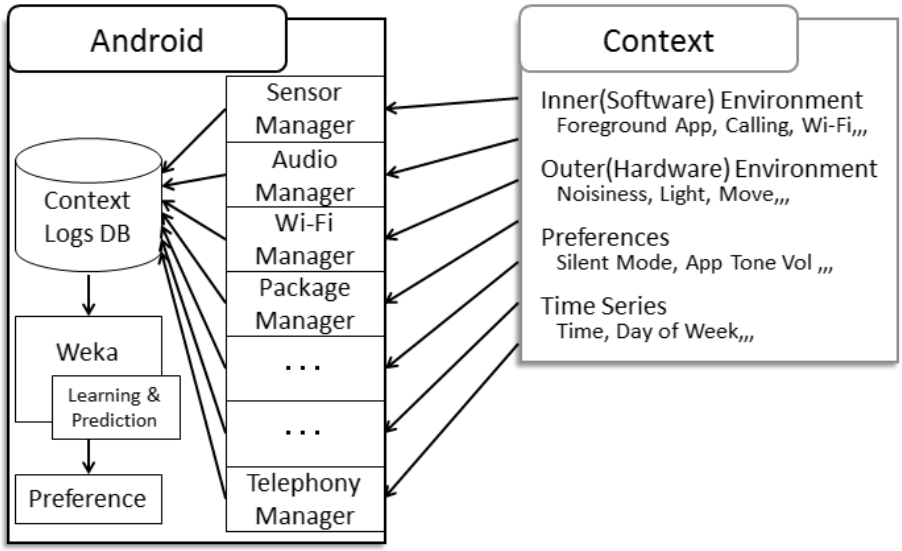


図 3.3: システム構成図

蓄積対象としたデータは表 3.2 のとおりである.【内部】と記載しているデータは次節以降で述べる前処理に用いられるデータであり，直接学習の属性として利用するわけではない．これらの情報は表 3.3 のイベント発生毎に観測され端末内部の DB に保存される．なお，GPS の計測に関しては Google I/O 2013 にて公表された GooglePlayServices の Fused Location Provider を利用し，優先度設定は，PRIORITY_BALANCED_POWER_ACCURACY とし，取得インターバルを 1 分とすることで電池消費を抑えて計測するものとした．この設定を用いたことで稀に精度の低い位置情報が計測されるが，次節の前処理で述べる手法を用いて簡易的に異常値，欠損値を補完している．また,「GPS クラスタ」とは，補完後の緯度経度情報をクラスタリングした結果であり，クラスタリングに関しては次節の前処理にて述べる．これらの情報を採用した理由は，アプリ音量の設定に関して大きく影響をもたらす因子であると判断したことからである．

3.3.2　前処理

蓄積したデータを用いてアプリ音量のオンオフを推定する前に，いくつかの前処理を行う必要がある．一つは GPS データに関する処理で，もう一つは学習における正解データの生成である．

本システムは GPS の観測に Fused Location Provider を利用し，優先度設定は，PRIOR-

表 3.2: 蓄積するデータの種類

番号	データ種類	概要
1	画面点灯	画面がオンかオフか
2	画面向き	画面表示が縦向きか横向きか
3	アプリ名	前面に表示されているアプリの名称
4	時刻	時刻
5	曜日	曜日
6	マナー設定	マナーモードの設定状態
7	ヘッドセット	ヘッドセットの接続があるかないか
8	GPS クラスタ	GPS クラスタリング ID
9	日時	【内部】日時の Long 値
10	緯度	【内部】GPS にて観測した緯度
11	経度	【内部】GPS にて観測した緯度
12	GPS 精度	【内部】GPS にて観測した精度
13	アプリ音量	【内部】設定しているアプリ音量

ITY_BALANCED_POWER_ACCURACY を利用すると述べたが，これは消費電力を抑えるために，GPS による測位を最小限に抑え，センサや Wi-Fi，3G による位置推定を行うものであり，しばしば低精度の位置情報が観測される．このことから，GPS データに関しては補完が必要であることがわかる．また，単純な緯度経度の情報はアプリ音量の推定に関して特徴をえることが難しいことから緯度経度情報をクラスタリングし有意位置を抽出することで属性値とする．GPS の異常値，欠損値補完は，対象データの前後で観測された確実なデータを用いて，直線移動を行ったと仮定し，経過時間とユークリッド距離による補完を行う．T_0 と T_n が正常に GPS を測位し，T_1 から T_{n-1} までのデータが GPS 異常値または欠損値であったとする．T_n の属性を { 時刻 (Time), 緯度 (Lat), 経度 (Lng)} とすると，図 3.4 のように以下の式で異常値，欠損値を補完する．Interval(X, Y) は X と Y の時間差であり，Distance(X, Y) は X と Y のユークリッド距離を示す．この計算を緯度，経度それぞれで実施する．なお補完対象は，T_0 から T_n の間隔が 5 分以内もしくは 1 時間以内だが

表 3.3: データ取得タイミング

タイミング	
画面オン	画面オフ
ヘッドセットが挿入された	ヘッドセットが外された
バッテリーが接続された	バッテリーが外された
近接反応があった	近接反応がなくなった
マナー設定がされた	マナー設定が解除された
電話を発信した	着信があった
通話が始まった	通話から待ち受けに戻った
Wi-Fi がオンになった	Wi-Fi がオフになった
Volume が変更された	時刻（分）が変化した
バッテリーが変更された	ホームボタンが押された

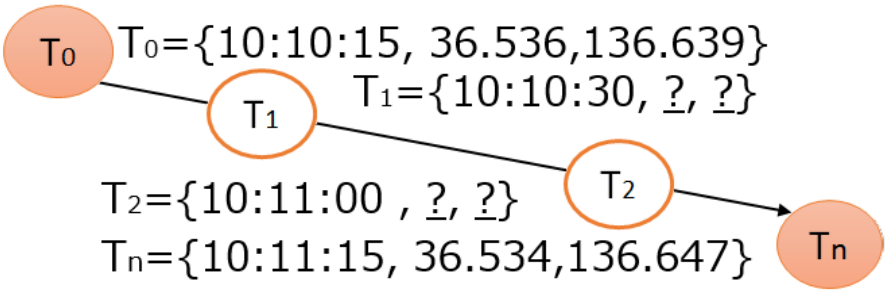


図 3.4: GPS 異常値，欠損値の補完

移動範囲が 50m 以内の場合としており，そのほかは欠損値とする．

$$T_i = T_0 + \frac{Interval(T_i, T_0)}{Interval(T_n, T_0)} \times Distance(T_n, T_0) \quad .$$

その後，補完された緯度経度情報を用いて，重要位置クラスタを生成する．重要位置クラスタとは，利用者が一定時間以上滞在していたという，利用者にとって意味のある位置クラスタである．例えば，利用者の家や駅，職場などである．クラスタリング手法は様々なものがある．例えば有名な k 近傍法はデータセットを重心をもとに k 個のクラスタに分類する手法である．しかし，緯度経度情報にこれらのアルゴリズムを単純に適用するだけでは重要位置クラスタは抽出することができない．そこで本研究では Kang ら [27] の Time-Based Clustering の手法を用いる．本手法は緯度経度情報に付帯する時刻情報を用いて，一定以

上の滞在時間を一定の移動範囲内で測位するときに重要位置としてクラスタリングを行う手法である．本システムはアルゴリズムがシンプルであり，かつ逐次的にクラスタリングを行うことができるため，本システムに適していることから採用した．特にシンプルであるという点はモバイル上での実装において電力消費が少ないこと，CPU 資源を消費しないことから重要であるといえる．なお，最小滞在時間と範囲のパラメータは標準値である 5 分と 50m としている．

3.3.3　学習データ

機械学習を行うにあたり学習の正解となる正解データを生成する必要がある．理想的には，利用者が逐一正解となる情報を入力することが望ましいが，現実的ではない．そこで本システムではアプリの利用単位という概念を提案し利用単位ごとで，アプリ音量がオンかオフかを判定し正解データとして利用する．利用単位とは利用者の一回のアプリ利用を定義するものである．利用者がホーム画面→ゲーム→ホーム画面と遷移して利用した場合，それぞれの画面で取得したインスタンスを一括して利用単位として考える．利用単位を区切る条件はアプリ名か画面点灯が変化するか，例外として前回のデータから（欠損値などの都合で）5 分以上経過した場合としている．表 3.4 は蓄積データのサンプルである．紙面の都合から一部を抜粋して記載しているが，特に重要なのは画面点灯，アプリ名，時刻，アプリ音量である．このデータにおいて利用単位を分類すると区切り線が入っている位置（2 行目，10 行目，14 行目）で利用単位が区切られている．また，利用単位ごとで，アプリ音量がオンかオフかの判断基準は多数決とする．表 3.4 において利用単位 2 つ目の Puzzle は，初期値としてアプリ音量がオンであるが，利用単位内ではオフが多数となるため，正解データはオフとする．したがって，3 行目，4 行目の Correct Data がオフ（False）になる．

3.4　評価実験 1

関連研究とは異なり，本システムはアプリ音量の推定に着目しており，かつ利用者からの正解情報や設定条件の事前入力を必要としない．したがって，単純に提案手法とマナーモードを自動設定する関連研究を比較することは難しい．したがって，本研究では本システムがどのくらい利用者の負担を減らすことができているかを，推定精度を考察することで評価する．本システムによるアプリ音量の推定精度を評価するため，スマートフォンの

表 3.4: 記録データサンプル

	Screen On or Off	Application Name	Time	GPS Cluster	Volume On or Off	Correct Data
1	ON	Home	1323	Place1	ON	True
2	ON	Home	1324	Place1	ON	True
3	ON	Puzzle	1325	Place1	ON	False
4	ON	Puzzle	1326	Place1	ON	False
5	ON	Puzzle	1327	Place1	OFF	False
6	ON	Puzzle	1328	Place1	OFF	False
7	ON	Puzzle	1329	Place1	OFF	False
8	ON	Puzzle	1330	Place1	OFF	False
9	ON	Puzzle	1331	Place1	OFF	False
10	ON	Puzzle	1332	Place1	OFF	False
11	ON	Home	1333	Place1	OFF	False
12	ON	Home	1334	Place1	OFF	False
13	ON	Home	1335	Missing	OFF	False
14	ON	Home	1336	Missing	OFF	False
15	OFF	Home	1337	Missing	OFF	False
16	OFF	Home	1338	Missing	OFF	False

日々の操作ログを取得する実験を行った．実験用アプリは表 3.2 のコンテキストを表 3.3 のイベントが発生したタイミングで記録し，定期的にサーバにログを送信する．観測したコンテキストと利用者が実際に使っていた設定を利用することで利用者の状況を推定することができるため，利用者が手動で音量を変更した回数，即ち本システムが軽減できるであろう利用者の負担を分析することができる．本システムは定期的に様々なコンテキストを記録することから，消費電力が増加することが懸念される．そのため，長期間被験者を募ることが難しい．今回大学生や大学院生，会社員など 9 名の被験者にて，7 日から 79 日の動作ログを取得した．平均観測日数は 30 日間である．また，この中でアプリ音量を逐次切り替えて利用している利用者は 5 名であり，5 名の利用期間は 13 日〜79 日間で，平均 41 日間/人である．精度評価には，アプリ音量を逐次変更していた 5 名のデータを用いる．

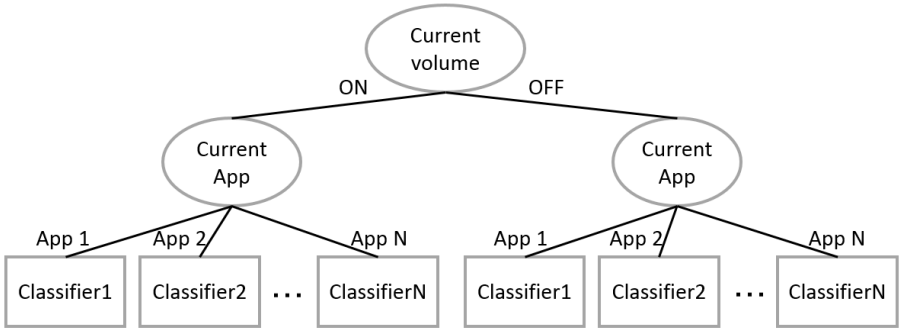


図 3.5: 本システムで採用している木構造識別器の概要

実験は次のステップで実施する．まず，3.3.1 節にて述べたステップにて正解データを生成する．次に，実際の利用環境と同じ状況においてシミュレーションを行い，本提案手法による予測結果を求める．そして，正解データと予測結果を比較する．シミュレーションとは，時系列に従って学習データを読み込み，時系列に従って学習を進める方式である．これを行うことにより，実環境で利用した場合の推定結果と同様の結果をえることができる．

3.4.1　識別手法

本システムはデータマイニングツール Weka による機械学習を用いてアプリ音量を推定する．特徴ベクトルは表 3.2 のから内部処理用の属性を除く 8 属性であり，前述した前処理にて計測される．アプリ音量は推定時の初期音量と表示している画面に強く依存すると考え，本研究では図 3.5 の構造の識別器を用いて推定を行う．

図 3.5 の葉に位置する最適な識別器を求めるために，様々な識別器を用いてシミュレーションを行い推定精度の比較を行った．利用した識別器は有名な 4 種類であり，Random Forest(RF)，サポートベクターマシン（SVM），ナイーブベイズ（NB），PART である．RF[28] は決定木を弱識別器としたバギングの手法であり，多数の決定木をランダムサンプリングと特徴のランダム抽出によって生成し多数決により推定を行う手法である．SVM[29] はカーネルトリックと呼ばれる手法を用いて，非線形文理問題に対しても効果的に識別が行える学習モデルである．NB[9] はベイズの定理をもとにしたシンプルな確率分類モデルである．PART[30] はルールベースの識別器であり，部分決定木を繰り返し作成することでルールを生成する手法である．パラメータは基本的に Weka の標準パラメータを用いている．RF では木の深さと特徴量数は無制限，木の数は 10 としている．SVM では RBF カーネ

表 3.5: 評価指標

		User adjusted		
		True	False	
System adjusted	True	TP(True Positive)	FP(False Positive)	PPV
	False	FN(False Negative)	TN(True Negative)	NPV
		Sensitivity	Specificity	Accuracy

ルをコスト 1，ガンマ 0 にて利用している．NB ではカーネル推定は利用していない．PART ではルール作成の最小オブジェクト数は 2 としている．

3.4.2　評価基準

本研究では [11] を参考に表 4.2 の評価指標を用いた．表中の True はアプリ音量がオンのことを，False はオフのことを示している．

$$
\begin{aligned}
Recall_T &= \frac{TP}{TP+FN} \\
Recall_F &= \frac{TN}{TN+FP} \\
Precision_T &= \frac{TP}{TP+FP} \\
Precision_F &= \frac{TN}{TN+FN} \\
Accuracy &= \frac{TP+TN}{TP+TN+FP+FN}
\end{aligned}
$$

$Recall_T$ とは利用者が音量をオンで使った合計回数のうち，システムがオンであると推定した回数の比率を示している．$Recall_F$ とは利用者が音量をオフで使った回数のうち，システムがオフであると推定した回数の比率を示している．即ち，どの程度利用者の意図を予測することができたかである．$Precision_T$ とはシステムがオンであると推定した回数のうち，利用者がオンで使った回数である．$Precision_F$ はシステムがオフであると推定した回数のうち，利用者がオフで使った回数である．即ち，システムの予測がどの程度あたったかである．そして全体を通じての正解率は Accuracy である．

さらに，本提案の精度改善の基準として比較対象となるデータを生成する．比較対象として「マナーモードとアプリ音量を連動した場合 (マナー連動)」を生成する．これを比較

表 3.6: 提案手法とマナーモード連動手法における予測精度比較

	$Recall_T$	$Recall_F$	$Precision_T$	$Precision_F$	Accuracy
マナー連動	52.0%(±41.9%)	99.9%(±0.1%)	99.4%(±0.7%)	78.0%(±18.6%)	80.1%(±17.2%)
RF	88.6%(±8.8%)	98.7%(±1.0%)	97.4%(±2.7%)	92.7%(±6.8%)	94.6%(±4.5%)
SVM	89.4%(±8.5%)	99.1%(±0.8%)	98.4%(±1.2%)	93.2%(±6.4%)	95.2%(±4.2%)
NB	88.6%(±9.1%)	98.6%(±1.0%)	97.3%(±2.7%)	92.8%(±6.6%)	94.6%(±4.4%)
PART	89.3%(±8.6%)	98.9%(±1.0%)	97.7%(±2.6%)	93.1%(±6.4%)	95.0%(±4.3%)

対象として採用した理由としては，アプリ音量とマナーモードの連動は実装可能な原理であり，単純なアプリ音量推定となりうると考えたため比較対象とした．

3.4.3　実験結果

表 3.6 は個人ごとにシミュレーションを実施した結果であり，平均値（± 標準偏差）の形式で記載されている．マナー連動となっている行はマナーモードに連動して音量を切り替える手法を採用した場合の推定精度である．RF，SVM，NB，PART の行は本提案手法をそれぞれの識別器にて実施した場合における推定精度である．なお，被験者 5 名のアプリ音量がオンとなっていたインスタンスの比率は 59.7%(±8.4%) となっている．

まず，マナーモード連動手法と提案手法を比較する．Accuracy に着目すると，マナーモード連動手法は 80.1%であるのに対し，提案手法はそれぞれ 94.6%，95.2%，94.6%，95.0%となっており，すべてにおいて高い結果となっている．その結果本提案手法はマナーモードと単純に連動する手法に対してより正確に予測ができているといえる．次に Recall に着目すると，マナーモード連動手法は最も $Recall_T$ が低く，$Recall_F$ が高い結果となっている．これは，マナーモードの設定値がアプリ音量オフと密接に連動していることが原因と考えられる．しかし，$Recall_T$ が低いことから，マナーモードであるが，アプリ音量をオンにして利用したいケースで予測精度が低くなっていることがわかる．また，各識別器による推定精度の比較を行った結果，全体的に僅差ではあるが，SVM の Accruracy が最も高い結果となった．

3.4.4　評価実験 1 の残課題と発展

評価実験 1 では，本システムによる予測結果を示したが，いくつかの課題が残っている．1 つは，実験に協力してくれたテストユーザが少なく，9 名中 4 名が定期的にアプリ音量を変更していなかったという点である．したがって，定期的にアプリ音量を変更する利用者の比率が不明確であり，本システムのターゲットとなる人々の比率が不明確であった．2 つ目は，不均衡データである．分析では，すべてのデータを正解データとして用いていたため，ほとんどのインスタンスが「利用者がアプリ音量を変更しない」ケースとなった．ほとんどのデータがアプリ音量を変更しないインスタンスだと仮定すると，利用者が理想とする音量は推定時の初期音量であると，本手法は学習してしまう可能性がある．3 つ目は利用者の平均精度に着目した点である．しかし，利用者には本システムが有効に働く利用者と，そうでない利用者がいることが想像できる．

また，関連研究では逐一被験者に最適な音量を尋ねることで理想の正解データを観測し，提案手法の検討を行っていた．しかし，被験者は実験時に毎回完璧な音量を選択する必要がある．この手法では，一般的な利用者に対し実験的な音量設定のモデルを構築することは可能であるが，個々の利用者の定常的な設定手法は学習できない．一方，我々の提案手法は実際のスマートフォンログを用いており，利用者は毎回完璧な音量設定を選択する必要がない．本研究の目的は，利用者に対して汎用的な音量設定のモデルを作ることでなく，実際のスマートフォンログから，日々利用者の定期的な設定を学習するシステムを構築することである．しかし，実際のスマートフォンログには，定期的な設定以外にも例外的な設定や，利用者の設定忘れなども含まれてしまう．これらをすべて学習させてしまうことで，正確に定期的な設定を学習する妨げとなる危険性がある．

3.5　評価実験 2

3.5.1　提案手法の修正

評価実験 1 における残課題を解決するために，提案手法の改良を行った．まず，学習に使用する特徴量を減らした点である．提案手法 1 では GPS により位置情報を観測し，GPS クラスタを特徴量として含めていた．しかし，GPS を用いると消費電力が上昇することから実用度が劣っていた．そこで，GPS での観測を行わず，ほとんど電力を消費せず観測で

きる情報のみを特徴量として用いることで，大規模なログの測定実験を実施することが可能とした．評価実験2では，低消費電力にて観測できる実際の動作ログを大規模に収集し分析することで，本システムの需要やより詳細な推定精度分析を実施する．

評価実験1では機械学習のアルゴリズムを，推定時の初期音量にて木構造を作り，その葉にそれぞれの学習器を用いる構造としていた．しかし，それでは推定結果が初期音量に強く影響をうけやすい．学習データ群は音量を変更しない（初期音量＝正解音量となる）インスタンスが大多数を占めているため，学習モデルが，初期音量＝推定結果となりやすく，自動設定が実現できない可能性が懸念された．そこで評価実験2では，木構造との組み合わせをやめ，単純な学習器を用いることとした．

関連研究では実験において被験者に適切な音量を完璧に入力させることで正解データとして用いている．利用者に正解データを入力させることは実用的でないため，本研究では実際のスマートフォンログから利用者の定期的設定を抽出するという手法を提案した．しかし，実際のスマートフォンログから生成されるインスタンスには，定期的な設定を機械学習する際に妨害となるものが多数存在することが大きな課題である．そこで本研究では，定期的な設定を学習する際に妨害となるインスタンスを予めルールベースで除外することにより，実際のスマートフォンログからのアプリ音量自動設定を実現する．

定期的な設定を学習するため，利用者が音量設定を決定するフローを図5.1と仮定した．まず，使っているアプリが音を発するかどうかで分岐する．音を発さないアプリの場合，利用者は音量を変更することはなく，かつ，その際の音量設定はオンでもオフでもどちらでも構わない．そのため音を出さないアプリのインスタンスは学習対象から除外する．次に，そのインスタンスが例外的な状況かどうかで分岐する．ここで例外的な設定とは，動画アプリで音量をオフにするなど，日ごろ頻繁に行う設定と異なる設定のことである．その他，利用者が設定を忘れて，いつもと異なる設定で利用しているケースも例外的な設定とする．例外的な設定は，定期的な設定の抽出という本研究の目的に合わないため除外したい．しかし，インスタンスが例外的な状況かどうかを正確に判断する基準はない．そこで，設定忘れのインスタンスをなるべく除外するために，利用時間が5秒以内のインスタンスを除外することとする．残ったインスタンス群を定期的な設定として，図5.1の「利用者の意思決定部」を機械学習にて実現する．

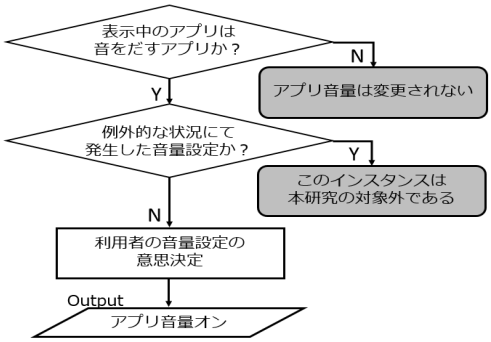


図 3.6: 利用者がアプリ音量を決定する際の思考フロー

表 3.7: 取得する情報の一覧

取得情報	概要
表示画面	表示しているアプリのクラス名
画面点灯	画面がオンかオフか
バッテリー接続	バッテリーに接続しているか
ヘッドセット接続	ヘッドセットに接続しているか
マナーモード	マナーモード設定内容
着信音量	着信音量の大きさ
アプリ音量	アプリ音量の大きさ

3.5.2　実験概要

評価実験 1 にて，9 名中 8 名がマナーモードを定期的に変更しておらず，9 名中 4 名が定期的にアプリ音量を変更していないという結果が得られた．そこで，評価実験 2 では，本研究の推定精度を考察する前に，本研究を求めている利用者層を分析する．そこで，実生活における大規模なスマートフォンログを取得する実験を行った．実験ではバックグラウンド常駐型のアプリケーションにおいて表 3.7 の情報を逐次記録している．アプリケーション導入時に利用規約において,「利用動向情報を研究，その他サービス向上などに利用することがある」ことを明記し，同意を行った利用者のみアプリケーションを利用できるようにしている．また，収集情報には個人を識別する情報（氏名，生年月日，連絡先など）は含んでいない．これらの情報は利用者が端末を操作するたびに記録を行っている．なお，これらの情報を用いて，評価実験 2 では次の点を考察する．

考察 1 本研究の対象となる利用者の比率を考察する

考察 2 マナーモード設定と曜日・時刻の関係性を考察する

考察 3 アプリ音量とアプリの種類の関係性を考察する

考察 4 修正した提案手法の有効性を考察する

3.5.3　考察 1（本研究の対象となる利用者の比率）

分析を行うため，全ユーザが均一の分解能を持つように，収集したログを一時間毎に区切ってインスタンス化する．インスタンス化した結果，異常値・欠損値を除外し，4 週間以上のデータが揃っている利用者のみに限定したところ，806 名が有効となった．平均観測日数は 71.6 日（± 36.6 日）で，おおよそ 140 万インスタンスである．音量変更を実施している利用者がどの程度いるのかを把握するため，一日一回以上マナーモード，アプリ音量を変更する確率を以下の式で計算し，図 3.7 にヒストグラムをまとめた．

$$\text{一日の設定変更確率} = \frac{\text{設定を一度以上変更した日数}}{\text{総観測日数}}$$

例えば，一週間において土日を除く平日 5 日間，毎日マナーモードを変更している運用を行った場合，7 日中 5 日間で 71.4%の確率で一日一回以上マナーモードを変更しているとみなす．図 3.7 のマナーモードに着目すると，70.0%までの累積度数は 45.3%となっている．したがって，約 5 割の利用者が一週間に 5 日以上，マナーモードを変更して運用していることがわかる．アプリ音量に関しても同様の分布が見られた．したがって，全体の半数程度の利用者はマナーモードやアプリ音量を定期的に変更していると考える．

3.5.4　考察 2（マナーモード設定と曜日・時刻の関係性）

まず時刻毎のマナーモード設定状況を分析する．例えば，ほぼ毎日朝 9 時～17 時はマナーモードを設定しているなどの運用をしている利用者を想定している．このような運用を行っている利用者を抽出するため，利用者毎に時刻別の平均マナーモード設定時間を図 3.8 の形式で一覧化した．図 3.8 では各利用者がそれぞれの時刻においてマナーモードを設定していた分数の平均値を計算している．例えば User1 は 9 時～19 時の間が約 40 と表示されていることから，9 時～19 時の間はマナーモードに設定していた日が多いことがわかる．同様に 0 時～7 時の間はとても低い値を示しており，マナーモードを解除していた日

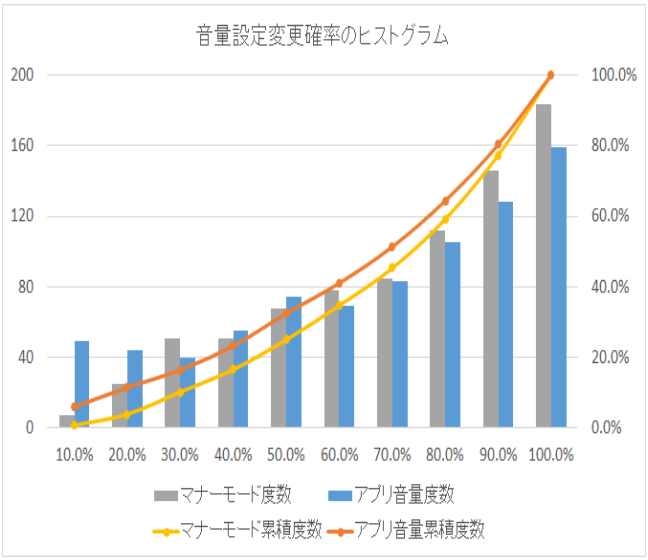


図 3.7: 一日に一回以上音量変更を行う確率のヒストグラム

	0時	1時	2時	3時	4時	5時	6時	7時	8時	9時	10時	11時	12時	13時	14時	15時	16時	17時	18時	19時	20時	21時	22時	23時
User1	4.2	3.3	1.9	1.9	1.9	1.9	1.9	1.9	20.9	35.1	37.9	41.1	41.7	40.5	40.0	40.0	40.0	40.0	38.7	32.0	23.5	18.8	17.5	11.8
User2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
User3	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0
User4	19.8	21.6	21.6	22.4	22.4	22.4	22.1	21.3	22.4	22.6	23.9	25.3	26.1	24.4	24.3	24.1	26.2	23.4	27.5	26.4	26.5	25.1	25.6	21.8

図 3.8: 時刻別の平均マナーモード設定時間の例

	0時	1時	2時	3時	4時	5時	6時	7時	8時	9時	10時	11時	12時	13時	14時	15時	16時	17時	18時	19時	20時	21時	22時	23時
Mon	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	22.0	36.0	46.0	48.0	48.0	48.0	48.0	48.0	48.0	48.0	48.0	59.9	49.0	45.0	37.1	20.3
Tue	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	21.8	44.3	45.0	45.0	45.0	45.0	45.0	45.0	45.0	45.0	38.9	30.0	30.0	30.0	30.0	16.9
Wed	1.3	0.0	0.0	0.0	0.0	0.0	0.0	0.0	44.2	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	46.7	27.2	15.0	15.0	13.2	0.0
Thu	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	25.0	58.6	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	59.2	38.7	30.3	12.0	12.0	12.0
Fri	1.7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	28.3	58.7	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	60.0	48.6	21.2	12.0	12.0	12.0
Sat	12.0	9.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	19.0	23.2	15.3	12.0	12.0	12.0	12.0	12.0	12.0	12.0	12.0	12.0	12.0
Sun	12.0	12.0	12.0	12.0	12.0	12.0	12.0	12.0	10.7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	12.0	12.0	12.0	12.0	10.0

図 3.9: User1 の時刻・曜日別の平均マナーモード設定時間

User4	0時	1時	2時	3時	4時	5時	6時	7時	8時	9時	10時	11時	12時	13時	14時	15時	16時	17時	18時	19時	20時	21時	22時	23時
Mon	0.0	0.0	0.0	0.0	0.0	0.0	0.0	6.5	10.0	3.4	8.4	11.9	14.1	10.1	8.6	13.4	17.1	11.5	0.0	0.0	6.6	20.7	32.5	29.9
Tue	34.3	34.3	34.3	34.3	34.3	34.3	34.3	34.3	34.3	42.2	42.9	43.7	42.8	42.9	42.9	42.9	41.1	28.4	41.1	42.8	30.9	25.1	34.7	20.2
Wed	22.4	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.9	40.0	36.0	40.0	40.0	43.2	34.2	23.9	20.0	20.0	20.0
Thu	26.7	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.0	30.8	22.8	20.5	29.9	20.0	25.7	29.4	39.5	37.7	36.2	23.9
Fri	19.9	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	20.0	17.1	17.1	30.2	19.1	9.8	13.9
Sat	6.7	6.7	6.7	6.7	6.7	6.7	6.7	6.7	6.7	6.7	11.6	20.4	15.1	12.0	13.2	16.4	16.4	13.0	21.0	21.8	22.1	26.8	23.8	24.7
Sun	27.8	30.0	30.0	32.7	32.7	32.7	31.6	24.2	27.3	27.0	25.9	24.6	32.1	28.4	27.2	25.6	26.3	33.1	42.2	37.8	31.9	26.2	26.8	19.7

図 3.10: User4 の時刻・曜日別の平均マナーモード設定時間

が多いことがわかる．なお，今回はバイブレーションとサイレントをあわせてマナーモードを設定しているとして分析を行う．

全利用者においてこの形式の表を作成したところ，利用者のマナーモード設定は大きく 4 種類に分類することができた．1 つは図 3.8 の User1 のように，ほぼ毎日時刻に応じてマナーモードを切り替えている利用者である．このような利用者は動作ログを学習することで利用者の設定パターンからルールを生成し，マナーモードの自動設定が実現可能であろうと考えられる．次に，User2 のようにすべての時刻において低い値を示す利用者がいる．このような利用者は定期的にマナーモードを切り替えず，常にマナーモードを解除している利用者である．同様に，User3 のようにすべての時刻において高い値を示し，常にマナーモードに設定している利用者もいる．そして，User4 のようにほとんどの時刻において中途半端な数値を示す利用者がいる．このような利用者は時刻に依存してマナーモードを設定するわけではなく，ほかの要因においてマナーモードを切り替えていると考えられる．

次に，User1 をさらに曜日別で分析したところ，図 3.9 の結果となった．User1 のログ観測期間は約 32 日であり各曜日 4〜5 日分のデータを集計している．これによって，平日の 9 時〜19 時にマナーモードを設定している日が非常に多く，特に水曜日〜金曜日は必ずマナーモードに設定していたことがわかる．それに対して土日はマナーモードを解除していた日が非常に多いことがわかる．したがって，User1 は平日 9 時〜19 時にマナーモードを設定し，0 時〜7 時にはマナーモードを解除する周期的な行動を行っており，土日は基本的にマナーモードを解除しているという傾向がわかる．したがって，このようなルールを適用することによって User1 に対する自動マナーモード設定が実現可能となる．同様に，User4 をさらに曜日別で分析したところ，図 3.10 の結果となった．User4 のログ観測期間は約 53 日であり，欠損値によりばらつきはあるが各曜日 6〜10 日分のデータを集計している．これによって，時刻のみでは分類不可能と思われた User4 も，月曜日の 0 時〜20 時や，土曜日の 0 時〜9 時はマナーモードを解除している日が非常に多く，火〜水曜日の日中時間帯などはマナーモードを設定している日が多いことがわかる．その他の中途半端な数値を示す時間帯を，曜日と時刻だけでルール化することは難しいが，一部の曜日と時刻において特徴的なルールを抽出することはできそうであるとわかる．

User1 や User4 のように，曜日と時刻でマナーモード設定をルール化できそうな利用者が存在することはわかったので，これらの利用者が全体に占める比率を考察する．そこで，User1 や User4 を識別するための簡易的な判断値として，各曜日各時刻における最大値と最

小値の差を用いた．例えば User1 であれば，最大値 60 と最小値 0 で，差は 60 となる．User4 では最大値 43.7 と最小値 0 で，差は 43.7 となる．一方，時刻と曜日だけではルール化が難しそうな User2，User3 では最大値と最小値の差が 0 に近くなる．しきい値は経験的に 30 として，判断値が 30 を上回る場合はルール化ができそうであるとしたところ，806 利用者中 215 利用者がルール化できそうであることがわかった．特に，マナーモードを週 5 以上で変更している 441 利用者中では 178 利用者となり，マナーモードを定期的に変更する利用者の 4 割は曜日，時刻からルール化できる可能性があることを明らかにした．

3.5.5　考察 3（アプリ音量とアプリの種類の関係性）

考察 2 で行った分析と同様に，アプリ音量のオンオフが時間と曜日に従属するかどうかを分析した．同様の判断値としきい値を用いたところ，806 利用者中 130 利用者がしきい値 30 を超え，時刻と曜日でルール化できる可能性があることがわかった．特に，アプリ音量を週 5 以上で変更している 392 利用者中では 91 利用者となったが，マナーモード設定に対して人数比が小さく，マナーモード設定ほど曜日と時間でルール化できる利用者が多くないことが明らかとなった．

続いて，アプリ音量はアプリの種類に従属するかどうかという点を考察する．考察にあたって，一時間毎に作成していたインスタンスではなく，一アプリ利用毎にインスタンスを再生成した．一アプリ利用毎とは前述のとおり，(1) 画面が切り替わるタイミング，(2) 画面がオフになるタイミングでインスタンスを切り分け，一回のアプリ利用を一インスタンスで表現することと定義している．前節同様の 806 利用者にて変換を行ったところ，欠損値や異常値を除き約 1200 万インスタンスが生成された．

生成されたインスタンスを，利用者毎にアプリ別でアプリ音量がオンである比率を求めた．その際，そのアプリ表示時に一度も音量が変更されなかったアプリと，アプリの総利用回数が 30 回以下のものは除外している．音量変更がなされなかったアプリは，恐らく音を発さないアプリであることが予想されるため除外の対象とした．続いて利用回数が 30 回以下のアプリは度数が少ないことから除外の対象とした．

表 3.8 はとある利用者らのアプリ別のアプリ音量をオンで利用する比率の表である．アプリ別に利用した回数，音量を変更した比率，音量をオンで利用していた比率と標準偏差である．User5 は全体的に音量をオンで使うことが多いが，お絵かきアプリ利用時のみ音

表 3.8: アプリ毎のアプリ音量をオンで利用する比率の例

利用者	アプリ	利用回数	音量変更率	音量オン率	(± SD)
User5	ブラウザ	669	1.6%	93.0%	(± 25.6%)
	設定	41	2.4%	87.8%	(± 32.7%)
	動画再生	1198	53.8%	97.2%	(± 16.6%)
	お絵かき	81	12.3%	22.2%	(± 41.6%)
	ランチャー	9035	0.1%	91.7%	(± 27.6%)
	テレビ電話	905	40.7%	95.5%	(± 20.8%)
	音楽プレイヤー	114	37.7%	94.7%	(± 22.3%)
User6	ブラウザ	111	2.7%	64.9%	(± 47.7%)
	設定	62	1.6%	35.5%	(± 47.8%)
	動画再生	156	43.6%	78.2%	(± 41.3%)
	音楽パズルゲーム	38	42.1%	94.7%	(± 22.3%)
	アクションゲーム	43	18.6%	23.3%	(± 42.2%)
	音楽ゲーム	47	27.7%	74.5%	(± 43.6%)
	パズルゲーム	56	17.9%	1.8%	(± 13.2%)
User7	ブラウザ	1089	0.4%	98.0%	(± 14.1%)
	ランチャー	8884	0.1%	99.4%	(± 7.5%)
	システム UI	147	0.7%	98.6%	(± 11.6%)
	動画再生	799	8.8%	100.0%	(± 0.0%)
	パズルゲーム	547	0.7%	99.5%	(± 7.4%)
	ピンボールゲーム	92	3.3%	95.7%	(± 20.4%)
	育成ゲーム	1478	0.7%	97.0%	(± 17.0%)

量をオフで利用することが多いなどの特徴がある．その他動画再生アプリやテレビ電話アプリでは音量をオンで使う比率が特に高く，音量変更率も高いことから，アプリを利用するたびに音量をオンに調整していると思われる特徴が見られた．続いて，User6 は全体的に中途半端な音量オン率を示しているが，音楽パズルゲームでは高い確率でアプリ音量をオンにし，一方アクションゲームやパズルゲームでは音量をオンにして利用している比率

がかなり低い．したがって，中途半端な値を示しているアプリは利用者の状況に応じて音量を切り替えているが，一部のアプリにおいてはアプリごとにオンとオフを使い分けているということがわかる．また，中途半端な確率を示しているアプリに着目すると，ブラウザや設定画面であった．Web ブラウザであればブラウザ上で動画を再生する際は音を上下させるが，通常操作時は音量を変更せずそのタイミングで設定されていた音量に従うことからばらつきが多くなることが予想できる．設定画面はソフトウェア的に音量を変更する際に利用している可能性が考えられる．これらのようにアプリごとに音量オンオフに傾向が見られる利用者がいる一方で，User7 のようにアプリごとに音量を上下させず基本的に音量をオンにしている利用者なども存在した．

以上の結果より，アプリ音量のオンオフは利用者によってはアプリの種類に従属しうることを確認できた．そこで，アプリごとに音量オンオフを使い分けていそうな利用者を識別するために，簡易的なしきい値として音量オン率の列が 95%より上もしくは 5%未満となるようなアプリがある利用者をカウントした．表 3.8 では，User5 は動画再生アプリを 97.2%音量オンで用いているため該当し，User6 はパズルゲームを 1.8%音量オンで用いているため該当する．しかしどのアプリもこの閾値に含まれない利用者は該当しないという方法である．カウントした結果 618 利用者が該当し，非常に多くの利用者アプリ音量オンオフを使い分けていることがわかった．したがって，時刻や曜日でルール化できない利用者に対しても，アプリ種別に応じてアプリ音量をルール化し自動設定が実現できる可能性を示した．

3.5.6　考察 4（修正した提案手法の有効性）

利用者にはアプリ音量を変更しない利用者が含まれているため，その中から頻繁にアプリ音量を変更している利用者を抽出して実験を行った．音量オンオフを切り替えている比率が，利用回数に対して 0.01 以上となる利用者を抽出した結果 107 名が抽出された．本提案手法の 107 利用者に対する平均推定精度を表 3.9 に示す．実験の前に，前処理として音を発さないアプリケーションもしくは 5 秒以内の利用となっているインスタンスの削除を実施した．最終的に本実験では 616 アプリを音を発するアプリとして採用した．表 3.9 はそれぞれの利用者に対しいくつかの手法を適用した場合の平均推定精度である．3.10 は我々の提案手法が特に有効に働いた 3 名の代表的な利用者の推定精度を示している．本手

表 3.9: 被験者 107 名の平均推定精度

Index	Note	Average	SD
(1)	音量オンで利用したインスタンス率	61.8%	23.4%
(2)	音量を変更しなかったインスタンス率	92.7%	4.39%
(3)	マナーモードと音量を連動する手法の推定精度	60.3%	21.3%
(4)	SVM による提案手法の推定精度	94.2%	3.38%
(5)	Random Forest による提案手法の推定精度	93.0%	4.50%
(6)	SVM と Random Forest の最大値	94.3%	3.38%
(7)	精度上昇率（(2) と (6) の差）	1.53%	2.21%

表 3.10: 代表的な利用者に対する推定精度

User	(1)	(2)	(3)	(4)	(5)	(6)	(7)
U1	60.5%	80.3%	60.4%	93.2%	85.8%	93.2%	13.0%
U2	70.6%	86.6%	94.9%	97.5%	98.0%	98.0%	11.4%
U3	96.9%	94.9%	77.4%	98.2%	99.1%	99.1%	4.25%

法は SVM[29] と Random Forest[28] を機械学習アルゴリズムとして採用している．今回の結果は，統計ソフトウェア R にて，randomForest パッケージと kernlab パッケージを用いて，10-fold-cross-validation にて自身のデータを学習推定した結果を示している．(6)SVM と Random Forest の最大値は (4) と (5) の最大値である．本システムはどちらかのアルゴリズムのみを用いるが，最終的に組み合わせて最大値を取ることができたと仮定した場合の推定精度を示している．(7) 精度上昇率は (2) アプリ音量を変更していないインスタンス比率から本提案手法によりどの程度自動化ができているかという値を示している．即ち，(7) は本提案手法によってどの程度利便性が改善されたかという数値を示している．

アプリ音量を変更しないインスタンスの平均比率は 92.7%のため，7.3%のインスタンスがアプリ音量を変更するインスタンスということになる．本提案手法を評価するにあたり，この 7.3%のインスタンスをどの程度自動設定にてカバーできるのかという点に着目する必

表 3.11: U1 の初期音量と正解音量のクロス表

		Correct AV		
		Off	On	Total
Current AV	Off	48	16	64
	On	16	82	98
Total		64	98	162

表 3.12: U1 のマナーモードと正解音量のクロス表

		Correct AV		
		Off	On	Total
Silent	Silent	0	0	0
	Sound	64	98	162
Total		64	98	162

表 3.13: U1 の SVM 予測結果と正解音量のクロス表

		Correct AV		
		Off	On	Total
Predicted AV	Off	59	6	65
	On	5	92	97
Total		64	98	162

表 3.14: U2 の初期音量と正解音量のクロス表

		Correct AV		
		Off	On	Total
Current AV	Off	189	72	261
	On	26	444	470
Total		215	516	731

表 3.15: U2 のマナーモードと正解音量のクロス表

		Correct AV		
		Off	On	Total
Silent	Silent	178	0	178
	Sound	37	516	553
Total		215	516	731

表 3.16: U2 の RF 予測結果と正解音量のクロス表

		Correct AV		
		Off	On	Total
Predicted AV	Off	205	5	210
	On	10	511	521
Total		215	516	731

要がある．本提案手法の推定精度は SVM で 94.2%，Random Forest で 93.0%となった．(2) と (6) の差は平均して 1.53%の上昇となったが，本提案手法が効果的に働く利用者と，そうでない利用者がいる点に注意しなければならない．例えば，表 3.10 は提案手法が有効に働く利用者代表例である．本稿では特に特徴的な 3 利用者に着目した．U1 は (7) の値が最も高かった利用者であり，U2 は次に (7) の値が高かった利用者，U3 は (6) の値が最も高かった利用者である．次章にて推定結果の詳細に関して議論を行う．本提案手法が有効に働く利用者数，即ち，(7) が 0%より大きい利用者は，92 利用者 (86.0%) となった．したがって，本提案手法は頻繁にアプリ音量を変更している利用者の 80%以上に対して有効に働くということがわかった．

利用者毎の詳細に関して考察する．まず改善率が最も高かった U1 に着目する．表 3.11，3.12，3.13 はそれぞれの手法におけるクロス表である．表 3.12 より，利用者は常にサウンドモードで利用しているが，アプリ音量はオンオフ切り替えて利用していることがわかる．

表 3.17: U3 の初期音量と正解音量のクロス表

		Correct AV		
		Off	On	Total
Current AV	Off	12	21	33
	On	2	412	414
Total		14	433	447

表 3.18: U3 のマナーモードと正解音量のクロス表

		Correct AV		
		Off	On	Total
Silent	Silent	8	95	103
	Sound	6	338	344
Total		14	433	447

表 3.19: U3 の RF 予測結果と正解音量のクロス表

		Correct AV		
		Off	On	Total
Predicted AV	Off	10	0	10
	On	4	433	437
Total		14	433	447

一方本手法は利用者の定期設定を学習し適切に自動設定を実現している．アプリべつで見てみると，U1 はゲームのアプリを音量オフで利用し，動画アプリを音量オンで利用する傾向が強かった．本手法はその傾向を学習し，適切に 93.2%の推定精度で推定できていた．

U1 の予測失敗パターンでは，動画を見ていた 12 インスタンス中 1 つが，本提案手法で予測失敗となった．失敗した 1 つのインスタンスでは，アプリ音量の初期値がオフとなっており，利用者が音量を変更しなかったインスタンスであった．成功した 11 インスタンスは音量オンで利用されており，本提案手法も音量オンと予測した結果である．失敗したインスタンスでは，利用者が音量を変え忘れたもしくは，音の関係ないコンテンツを閲覧していたものと仮定すると，動画アプリ利用時の音量設定は適切に学習できていたといえる．また，RPG では 14 インスタンス中 2 インスタンスにおいて予測失敗となった．しかし，失敗に 2 インスタンスはアプリ音量を変更していないインスタンスのため，利用者が設定を忘れていたという可能性がある．ログからは本当に設定忘れであるかということを確認する方法はないが，仮に設定忘れとすると，利用者が変更を忘れていた場合でも本手法は適切に変更できており，非常に適切に効果を発揮したといえる．実際のログでは U1 は 32 回手動で音量を変更していたが，本手法を用いていた場合 U1 は 11 回手動で変更するだけでよい．

続いて，予測精度が非常に高かった U2 と U3 に着目する．表 3.14 から 3.19 はそれぞれ利用者へそれぞれの手法を用いた場合のクロス表である．表 3.10 の 3 行目 (3) のとおり，U2 はマナーモード設定と強く関連していることがわかる．表 3.15 より，U2 はマナーモードに設定している際必ず音量をオフで利用していることが読み取れる．それらの定期設定を学習した上で，本提案手法は 98%の推定精度で定期的な設定を学習している．表 3.10 の 4

行目 (1) より，U3 はおおよそアプリ音量をオンで利用していることがわかる．それらの定期設定を学習し，本提案手法は約 99%の精度で定期設定を学習することに成功している．

利用者の中には，U1 のようにマナーモードを常にサウンドモードで利用する利用者がいたり，U2 のようにマナーモードをバイブレーションやサイレントに設定しているときは常に音量をオフで利用する利用者がいたり，U3 のように多くの場合において音量をオンで利用する利用者がいたりする．したがって，万人に有効に働く特徴やモデルを示すことはできない．その上で，上述した結果のとおり，本提案手法はそれぞれの利用者の状況や特徴を学習していくことにより，柔軟にアプリ音量の自動設定を実現できている．

結果として，定期的な設定を学習することで，一部の利用者らに対し本提案手法が有効で働いていることがわかった．エラーパターンより，今回の学習データは利用者の設定忘れを含んでいるため，必ずしも今回の推定精度が正しいとは限らない．本提案手法は利用者の例外的な設定は学習することができないため，それらの不必要な学習データをいかにして削減するかが今後の課題である．

3.6　おわりに

本研究の目的はスマートフォンから観測するコンテキストを用いて利用者のサポートを行うことであり，特に本章では，スマートフォンの音量設定に着目し，スマートフォンにおける音量設定の自動切り替え手法を提案した．利用者の音量設定忘れを防止することで，周囲への迷惑や，自身の集中力を阻害する要因を減らすことができる．

評価実験 1 として，実際に 9 名にてコンテキストを測定し精度評価を実施した結果，単純にマナーモードと連動する手法に対して，本システムのほうがより正確に最適な音量を予測することができた．しかし，利用者 5 名の平均精度を比較しているため，利用者毎の精度比較は実施していないが，利用者の中にはマナーモードに強く連動した設定を行っている利用者も見られた．また，提案手法が高い推定精度を示したことは，単純に利用者が初期値になっていた音量を変更することが少なかったからという理由が大きいものと考えられる．

評価実験 2 として，評価実験 1 の課題を踏まえて，低消費電力で得られるスマートフォンログを，一般利用者から大規模に収集する実験，考察を行った．その結果，マナーモードやアプリ音量をどの程度の利用者が日々変更しているのかという利用者属性や，マナー

モードやアプリ音量の設定が時刻や曜日に従属するのかどうか，従属するのであればどの程度の利用者が従属するのか，アプリ音量に関しては音量のオンオフがアプリの種類に従属するのかどうかという点の考察を行った．マナーモードの設定に関しては 806 利用者中 215 利用者に対して，アプリ音量のオンオフに関しては 806 利用者中 130 利用者に対して，曜日と時刻によるルールベース自動化の実現可能性を示した．さらに，アプリ音量がアプリの種別に従属しうる利用者が 618 名いたことを明らかにし，アプリの種類ごとにルールベースで音量のオンオフを自動化できる可能性を示した．

最終的に，評価実験 1 での提案手法を改善し，インスタンスの選定を行うことで，実際のスマートフォンログから定常的な設定だけを抽出する手法を提案した．改善後の手法の推定精度を同様に評価した結果，アプリ音量を頻繁に変更している利用者のうち 86.0%の利用者に対して本提案手法が有効に効果を発揮していることを明らかにした．個別の利用者に着目してみても，利用者毎に特徴を抽出し定期的な音量設定を学習できていることがわかった．

以上の考察を明らかにしたが，今後の発展に向け次の 3 点を今後の課題とする．(1) インスタンスの選別条件を変え，より正確に不要なインスタンスを削除する．(2) インスタンス選定を行った場合と行っていない場合における，例外的な設定の減少率を考察する．(3) アプリケーションとしての実装を行い，実働環境におけるユーザビリティを評価する．

第 4章

スマートフォンの所在状況推定システム

4.1　はじめに

本研究では，スマートフォンの所在状況を推定するシステムを提案する．スマートフォンの所在状況とは，ズボンのポケットの中や，机の上などの「スマートフォンがどのような状況にあるのか」と定義する．コンテキストアウェアネスの研究分野では，各種センサを用いて利用者の状況を推定する研究が盛んに行われている [14, 17, 31]．これらの研究では各種センサによる観測値を分析することで，利用者の行動認識を行っているが，センサ値はセンサ自体の帯同場所に依存することも知られている [32]．そのため，スマートフォンによるコンテキストアウェアネス研究では，スマートフォンの状況を把握する技術が望まれており，スマートフォンの所在状況推定システムを実現することで，帯同場所に応じた，より正確な行動認識を実現できると考えられる．

利用者の視点で見ると，利用者の予定やスマートフォンの所在状況によって通知方法を適切に変更することが望まれていると，Lopez-Tovar らの調査 [33] が示している．机上にある場合は LED 点灯で通知し，ポケットの中にある場合はバイブレーションで通知するほうが良いなど，スマートフォンの状況に応じて適切な設定を利用者は希望しており，本提案によりそれが実現できる．そのほかにも，特にタッチパネル式のスマートフォンにおいては，鞄やポケットの中での誤動作が問題となることがあるが，スマートフォンの所在状況がわかることで，ポケットや鞄の中にある際に誤動作を防止するなどの応用が可能となる．したがって，スマートフォンの所在状況推定システムを実現することで，帯同場所に応じたコンシューマサポートが実現できる．

スマートフォンの所在状況を推定する関連研究として，[34] では，加速度センサや地磁気

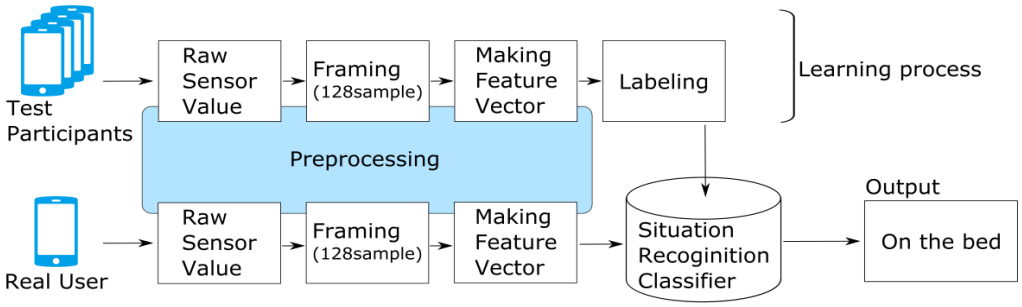


図 4.1: State Magic のシステム概要

センサなどを用いて，スマートフォンの帯同場所推定に取り組んでいる．ズボンのポケットや鞄の中など 4 状態からどのような状況にスマートフォンがあるのかを推定している．同研究では帯同場所を用いて，利用者の向いている方向を推定する研究を行っている．ただし，歩行動作はデバイスの位置を独立的に捉えやすい行動であり，日常で最も頻繁に行われる動作の 1 つである [35] という理由から，利用状況は歩行時に限定されている．藤波ら [36] はスマートフォンの加速度センサを用いて，スマートフォンの帯同場所を推定する研究を行い，首から下げる，胸ポケット，ジャケットポケット，ハンドバッグなどの 9 状態からどのような状況にスマートフォンがあるのかを推定している．こちらも歩行時という制限があるが，後の研究 [37] において，格納動作を用いた補正手法を提案している．両研究は常時センサ値を観測し機械学習で分類を行い，端末の帯同場所を推定する手法を採用している．一方，バイブレーションの反響を用いたスマートフォンの所在推定に関する研究も行われている [38]．端末を自ら振動させた反動から発生する音を用いて所在を推定する手法であり，柔らかい素材の上か硬い素材の上かという判定を 99%の精度で識別できたとしている．

関連研究 [35, 36, 37] では，帯同場所に依存するセンサ値の影響を抑えることを目的とした，利用者の歩行時の帯同場所を推定する研究であると述べられている．本研究ではスマートフォンの所在状況を，通知方法などのコンシューマ向けアプリケーションに応用するという利点に着目する．そこで，スマートフォンの所在状況を「手の中」,「鞄の中」,「ポケットの中」,「机の上」,「布団の上」,「スマートフォンスタンドの上」の 6 種類と定義し，各種センサ値を常時分析することによって，スマートフォンの所在状況推定システム「State Magic」を実現する．バイブレーションの反響による手法 [38] では，判定用の振動を通知

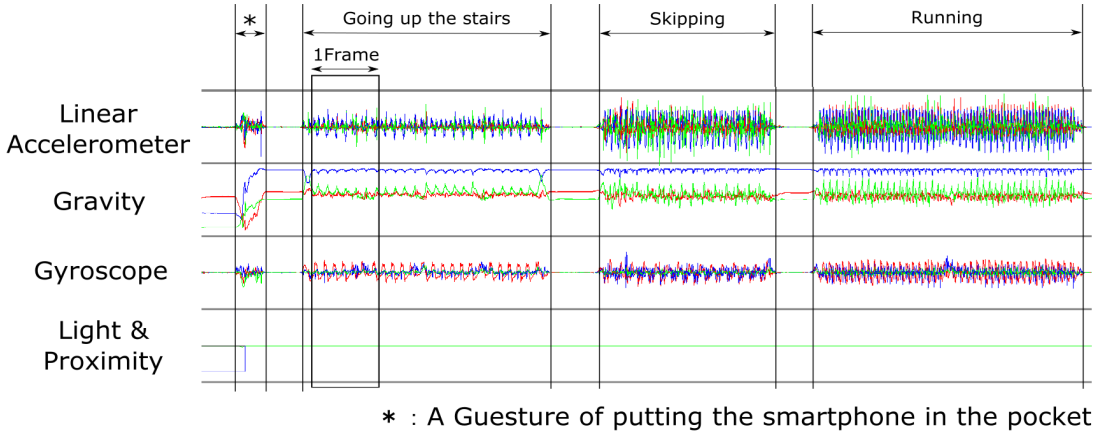


図 4.2: センサー値の処理方法

と誤解させてしまう可能性があり，ユーザビリティの低下を招く危険性がある．そのため，推定手法にはバイブレーションの反響による判別手法は用いず，各種センサ値を機械学習で識別する手法を用いる．

本研究では既存研究とは視点を変えて，6 状態識別に取り組むが，単純に既存手法を適用するだけでは後学に寄与できないと考える．そこで本稿では，藤波らの手法 [36] をベースに，以下の点を新たに拡張し，実験考察を経て新規性を主張する．

1. 機械学習に使用する特徴量の再考 : 加速度センサに加え，複数センサや重力方向を利用した場合の推定精度の変化を考察する（4.3.3 節）．

2. 利用者行動に対する頑健性の調査 : 歩行時のみでなく様々な利用者動作が発生する状況における頑健性を調査する（4.3.4 節）．

3. 6 状態識別問題への適用 : 本研究の目的である 6 状態識別問題における推定精度を考察する（4.3.5 節）．

4.2　提案手法

4.2.1　State Magic

本システム State Magic は Android スマートフォンから観測できるセンサ値をインプットとし，予測されたスマートフォンの状態をアウトプットとする識別器である．インプッ

トとなるセンサは Android スマートフォン端末に一般的に標準搭載されているセンサの中から，4 センサ（加速度センサ，ジャイロセンサ，照度センサ，近接センサ）を観測対象とした．これらのセンサは状態識別に影響を及ぼすであろうということから採用した．サンプリング周波数は約 50Hz（Android における SENSOR_DELAY_GAME）となるように設定している．ただし，照度センサや近接センサに関しては，端末によってイベンド駆動であったり，サンプリング周波数が大きく異なる．

アウトプットとなる状況は一般的にスマートフォンが存在するであろう状況を網羅した結果,「手の中」,「鞄の中」,「ポケットの中」,「机の上」,「布団の上」,「スマートフォンスタンドの上」の 6 種類を推定対象とすることとした．なお,「机の上」とは水平で固めの素材の上という定義を総称し,「布団の上」とは布団や座布団など柔らかい素材の上という定義を総称する．スマートフォンの通知方法に応用を検討する際，固いものの上か否かという指標は役に立つであろうという点から区別することとした．

図 4.1 は本システムのシステム概要である．上部は学習処理であり，下部は実際の運用時の処理である．共通する処理として前処理（Preprocessing）が実施される．学習時には手動でラベリングを行い，識別器を訓練する．運用時には前処理後，識別器で状態の判定を行う．

本研究では識別器に Random Forest[28] を用いる．Random Forest は，弱識別器として決定木を複数構成し多数決をとる手法である．決定木を構成する際に，学習データのサンプリングに加えて，特徴量もサンプリングされる．今回次元数の多い特徴をあつかうことから Random Forest を採用した．実験では統計ソフトウェア R 上で randomForest パッケージを用いた．本来，最適な特徴選択を実施した上で，最適な識別器を選択するという試行錯誤を重ねることが望ましいが，本稿では最高精度を記録することではなく，特徴量の増減による推定精度の変化や，利用者行動による推定精度への影響などを考察する点を新規性と主張することから，識別器に関する議論は行わない．

4.2.2　特徴ベクトルの生成

始めに，システムは図 4.2 のような生データを観測する．図の例では利用者は＊区間でポケットへの格納動作を行い，少し後に階段を上り，スキップを行い，走行を行っている．例では各動作間の間に一時停止動作を行っている．フレーミング処理ではこの生データを

一定長の窓に区切って特徴ベクトルの抽出を行う．本稿では応答性を考慮した結果，128 サンプルを 1 フレームとして用い，実験用のデータセット生成時にはこれを 30 サンプルずつスライドして特徴ベクトルを生成している．

次に，フレーミングされたデータから特徴ベクトルを抽出する．今回特徴ベクトルの候補には付録の表 1（506 次元）を Random Forest 内で特徴選択を実施した．学習時にはこれに正解となるラベルを付与する．実際のデータは停止，歩行，走行などの間に動作の切り替え区間が存在する．フレーミング時においても両状態が存在する区間は抽出されるが，今回はそのような複数状態を含む特徴ベクトルは対象としない．したがって，運用時には最大 1 フレーム分（128 サンプル=約 2.56 秒）識別タイミングが遅延する可能性がある．格納場所判定には，図 4.2 の＊区間のようなポケットへの格納動作を用いる手法も研究されている [37]．機械学習による格納場所判定において，利用者が静止している状況では識別が難しいという問題を可決する有用な手法であるが，格納動作は手に持った状況からポケットに入れるという動作だけでなく，机においた状態からそのままポケットに入れるパターンや，かばんから取り出してポケットに入れるパターンなど，パターン数が多く，学習データが大量に必要となることが懸念される．したがって，本研究では定常状態による識別に着目する．

今回実験時には 2 次元分のラベルを手動で付与する．一つは利用者の動作（直立，着座（椅子），着座（地面），左向寝そべり，右向寝そべり，うつ伏せ，仰向け，歩行，走行，スキップ，階段上り，階段下り）であり，もう一つはスマートフォンの状況（手の中，鞄の中，ポケットの中（5 種），机の上，布団の上，スマートフォンスタンドの上）である．利用者の動作は本来スマートフォンの状況推定時には未知の情報であるが，利用者の動作による識別器の頑健性を考察する際に用いる．詳細は次章で説明する．

4.2.3　重力加速度成分と加速度成分

本研究では加速度センサで観測される離散データを，重力加速度成分と加速度成分に分離し，それぞれで特徴ベクトルの生成を行う．関連研究においては端末の向きによる影響を抑えるため，重力成分を除去したデータを用いているが，本研究では端末の向きがスマートフォンの状況推定に役立つと考える．そこで，加速度成分から得られる特徴ベクトルに加えて，重力成分，ジャイロセンサ，照度センサ，近接センサから得られる特徴ベクトル



図 4.3: Android における加速度センサの軸方向

を複合的に用いる．

Android スマートフォン搭載の加速度センサの軸方向は図 4.3 となっている．即ち，画面を上にして机上においた場合，Z 軸に重力加速度である 9.8 が観測される．端末の動きを観測するには，重力加速度成分と加速度成分を分離して考えることが望ましい．本システムでは，観測した加速度センサ値に対して式 (4.1) のローパスフィルタを適用し重力加速度成分を抽出し，加速度センサ値から重力加速度成分を減ずることで加速度成分を抽出する．なお，S_t, G_t はそれぞれ，時刻 t におけるセンサ値，重力値を示しており，係数 α は 0.05 とした．

$$G_t = \alpha S_t + (1-\alpha) G_{t-1} \tag{4.1}$$

4.2.4　特徴量

提案手法では付録の表 1 で一覧表記している特徴量を，1 フレームごとに特徴ベクトルとして生成し，識別器を訓練する．特に我々は，識別時に有意に働くと思われる多くの特徴量を，複数センサを用いて観測しており，Random Forest において特徴選択を実施している．ここで，採用したセンサと 1 フレーム分の離散値から特徴量を計算する過程について，補足を述べる．

採用したセンサは，加速度センサ，ジャイロセンサ，照度センサ，近接センサであり，加速度センサは重力成分と加速度成分に分離して処理を行う．加速度成分は利用者の動きや

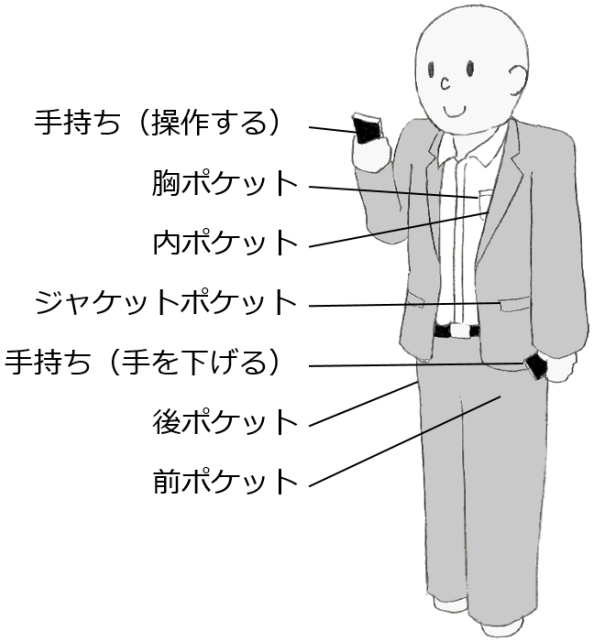


図 4.4: スマートフォンの格納場所一覧

静止を観測することができ，関連研究でも重力成分を除いた加速度成分を用いた識別が主流となっている．関連研究では，重力成分は端末の方向に強く影響をうけてしまう懸念から，重力成分を用いていなかったが，本研究では静止状態を取りあつかうことから重力成分は非常に重要な特徴と考え採用した．ただし，端末の向きに影響をうけることや利用者の体勢に影響をうけることが予想されることから，実験時に様々な向きや体勢によるデータを取得することで，頑健性を考察する．照度センサと近接センサは一般的にスマートフォン端末上部に装備されているセンサで，周囲の明るさと物体の近接を検出することができるセンサである．机の上や布団の上などの状況も推定対象としているため，照度や物体の近接が識別に役立つと考え採用した．

特徴量候補は関連研究 [36] に倣って，付録の表 1（506 次元）とした．絶対値の平均値とは，元データを絶対値にした後で平均値を算出するものである．同様に絶対値の標準偏差は元データの絶対値から標準偏差を算出するものである．二乗平均平方根とは値を二乗で合計して平方根を算出するものである．第 1 四分位数，中央値，第 2 四分位数は，フレーム内の離散値を昇順に並べ，4 分の 1，2 分の 1，4 分の 3 の位置になる値である．周波数成分に関しては，128 サンプルを FFT 処理し，全周波数領域，低周波数領域，中周波数領域，高周波数領域で同様の特徴量を算出している．なお，低周波数領域は 0〜4.2Hz，中周波数領域は 4.2〜8.4Hz，高周波数領域は 8.4〜12.6Hz としている．それぞれの特徴は x，y，

表 4.1: 実験時の作業パターン一覧

端末状態	利用者状態	パターン数
・ポケット：5 種類 × 上下向き （前，後，胸，内，ジャケット） ・手持ち：2 種類 （操作する，手を下げる） ・鞄 *（各自準備）	・動作：5 種類 （歩行，走行，スキップ，階段昇降） ・停止状態：7 種類 （直立，着座（椅子），着座（地面）， 左右向寝そべり，仰向け，うつ伏せ）	153 パターン
・机の上 ・布団（座布団）の上 ・スマホスタンドの上：2 種類 （置型，はめ込み型）	・操作する ・操作しない ・裏向きで置く	12 パターン

∗ 鞄では寝そべり 4 種は実施せず，代わりに，鞄を持たずに地面に置く動作を実施する．

z 軸それぞれに関して実施するのに加え，合力 g に関しても算出している．

4.3　評価実験と考察

4.3.1　実験概要

提案手法による精度評価と考察のための実験を行った．実験では，加速度センサ，ジャイロセンサ，照度センサ，近接センサを作動させたスマートフォンを，表 4.1 の状況において被験者に利用させデータを収集する．被験者はセンサを作動させた後，各端末状態にスマートフォンを格納し，表 4.1 にある行動をそれぞれ 20 秒間程度実施する．端末状態と利用者状態を組み合わせ，スマートフォンが取りうる状態を合計 165 パターン計測している．今回特徴量に重力成分を用いるため，ポケット格納操作は上向きに格納する場合と下向きに格納する場合や，利用者が 4 方向を向いて寝そべっている場合を計測している．端末状態にあるポケットと手中は図 4.4 の場所を示している．被験者は 21 歳〜26 歳の男子大学生，大学院生ら 6 名である．服装は各自測定時に着用していたものを用いているため，利用者によってはスーツのようなジャケットではないこともある．鞄はハンドバッグ，ショルダーバッグ，リュックサックなど各自準備したものを用いている．測定に用いた Android 端末は複数種用いており，内訳は Samsung 社製 GalaxyNote3（Android4.4.2）が 2 名，同社製 GalaxyS2（Android4.0.3）が 2 名，Sony 社製 Xperia Z3（Android4.4.4），同社製 Xperia Z3 compact（Android4.4.4）を各 1 名となっている．

4.1 章末尾で，本研究は関連研究に対して別問題（6 状態識別）に取り組んでいること，複数センサを併用していること，利用者状態に対する頑健性を示すことの 3 点を新規性とすることを説明した．ここで改めて関連研究との違いについて詳細に述べる．

関連研究との最も大きな違いは 6 状態識別に取り組んでいるという点である．関連研究では各種ポケットや各種鞄の中など 9 状態識別に取り組んでおり，前提として歩行時のみという制約がある．それに対して，本研究では机の上や布団の上，スマホスタンドの上など，利用者から離れている状態も識別対象としている点と，ポケットや鞄においても利用者が停止している状態も識別対象としている点が大きく異なる．6 状態識別を行うにあたり，重力成分を除く加速度センサによる特徴のみでは識別が難しいと判断し，本提案手法では重力成分，ジャイロセンサ，照度センサ，近接センサによる特徴量を新たに追加した．さらに，本提案手法が利用者の行動に対し頑健であることを示すため，様々な利用者状態におけるデータを分析している点も特徴である．

4.3.2　評価指標

実験結果の考察を行うにあたり，本稿で用いる評価指標に関して説明する．本稿では最終目標を 6 状態識別問題とする識別器の性能を評価する．識別器の評価には様々な指標があるが，本稿では特に F 値（F-measure）と推定精度（Accuracy）に着目して議論を行う．F 値とは，識別結果の再現率（Recall），適合率（Precision）の調和平均であり，識別したい状態に対する識別性能を評価する際に用いられる指標である．それぞれの指標は表 4.2

表 4.2: 評価指標の定義

		正解の状態		
		状態 A	状態 B	
予測結果	状態 A	TP	FP	$Precision_A$
	状態 B	FN	TN	$Precision_B$
		$Recall_A$	$Recall_B$	Accuracy

をもとに以下の式で計算される．

$$
\begin{aligned}
Recall_A &= \frac{TP}{TP+FN} \\
Precision_A &= \frac{TP}{TP+FP} \\
F\text{-}measure_A &= \frac{2 * Recall_A Precision_A}{Recall_A + Precision_A} \\
Accuracy &= \frac{TP+TN}{TP+TN+FP+FN}
\end{aligned}
$$

4.3.3　新規特徴量による精度変化の考察

複数センサの特徴量を追加したことによる精度変化を考察するために，本提案手法による付録の表 1 の全特徴量を用いたデータセット A より，加速度センサから得られる特徴のみで構成されるデータセット B を抽出し，それぞれにおいて識別実験を行った．自己データを含むすべてのデータから Cross-Validation 評価を行った場合，非常に精度がよくなることが確認されている [36]．本研究においても同様に高精度を記録した．そのため，関連研究同様に，自己データを学習させない Leave-one-subject-out Cross-Validation（LOSO-CV）によって精度評価を実施した．本研究の最終目標は 6 状態識別であるが，本節では関連研究の一部に倣って，ポケットを 5 状態分定義して実験を行う．ただし，本研究では首から下げるという状態を除外し，代わりに内ポケットを採用している．近年のスマートフォンにはストラップを取り付ける箇所がない機種が多く，首から下げる人が少ないことと，関連研究では内ポケットが検討されていなかったことを踏まえ，これらを採用している．

データセット A による実験結果とデータセット B による実験結果を表 4.3 に示す．10 状態識別問題に対する全体の Accuracy はデータセット A で 61.2%，データセット B では 51.0%となり，特徴量を増やしたことにより精度の向上が見込めることを確認した．各状態毎の F 値に着目すると，全体的に全特徴量を利用した場合のほうが高い値を得ているが，胸ポケット，内ポケット，鞄の識別精度に関しては大きな差は得られず，ともに識別精度が低い結果となった．これは関連研究でも議論されていたが，胸ポケットと内ポケット，物によっては鞄の身体的位置が近接していることから，特徴ベクトルに大きな差が現れなかったことが原因と思われる．また，机とスマホスタンドの上に関しては，全特徴量を用いることで F 値が圧倒的に向上する結果となった．これは重力成分や照度，近接センサによる特徴が大きく影響を与えているものと考えられる．

表 4.3: 全特徴量を利用したデータセット A と加速度のみを利用したデータセット B における LOSO-CV の F 値比較

	データセット A	データセット B	A - B
前ポケット	69.7%	61.5%	8.2%
後ポケット	75.5%	60.1%	15.4%
ジャケット	54.2%	38.8%	15.4%
胸ポケット	46.9%	46.4%	0.5%
内ポケット	23.6%	21.5%	2.1%
鞄	37.3%	32.9%	4.4%
手持ち	80.7%	72.0%	8.7%
机の上	62.6%	25.6%	37.0%
布団の上	35.4%	23.6%	11.8%
スマホスタンド	84.7%	49.2%	35.5%
Total accuracy	61.2%	51.0%	10.1%

また，データセット A の全データを用いて Random Forest でクロスバリデーションを実施し，特徴量毎の重要度を求めたところ，上位に来る特徴の多くは重力成分となっていたことから，重力成分の重要性がわかった．

4.3.4　利用者の動作に対する頑健性の考察

いくつかの関連研究では，利用者がスマートフォンを帯同しており，かつ歩行時のみという制約の上で端末の状態推定を行っている．[34] の研究のように歩行時に向いている方向を推定する状況においては，歩行時のみという制約は大きな問題とならないが，本研究が対象とするコンシューマサービスへの応用を考慮した 6 状態識別においては，利用者の様々な動作を考慮する必要がある．本研究では利用者が取りうる頻度の多い 12 パターン（表 4.1 の動作 5 種＋停止状態 7 種）においてデータを観測している．利用者の動作は端末状態を識別する際には本来未知の項目であるが，既知であると仮定した場合における推定結果と比較することで利用者の動作に対する頑健性を考察する．

利用者動作が未知である本来の環境とは，識別器を 1 つ単体で用いる手法（提案手法）

表 4.4: 提案手法採用時の利用者状態別推定精度

		提案手法	比較対象	提案 - 比較
動作	歩行	75.9%	77.3%	-1.5%
	走行	67.4%	65.7%	1.6%
	スキップ	68.4%	67.0%	1.4%
	階段下り	70.0%	71.6%	-1.6%
	階段登り	72.5%	75.6%	-3.1%
停止状態	直立	51.5%	51.1%	0.4%
	着座（椅子）	51.0%	64.5%	-13.6%
	着座（地面）	50.7%	58.8%	-8.1%
	右向寝	36.5%	58.1%	-21.6%
	左向寝	44.9%	52.3%	-7.4%
	仰向寝	50.5%	48.6%	1.9%
	うつ伏せ寝	47.4%	60.4%	-13.0%
全状態		61.8%	65.8%	-4.0%

である．それに対し，利用者動作が既知であると仮定し，利用者動作毎に学習を行うとは，利用者の動作毎にデータセットを分割し，データセット毎に識別器を訓練する方式（比較対象）を意味する．

これらの手法で実験を行った結果を表 4.4 にまとめた．全体の精度は提案手法で 61.8%，比較対象では 65.8%となり，当然ではあるが利用者動作が既知であるほうが推定精度が向上している．しかし，歩行，走行，スキップ，階段上り，階段下り，直立，仰向寝に関しては，利用者状態が既知であったとしても推定精度に大きな変化が現れなかった．このことから，これらの状況においては，利用者の状況に依存せず表 4.4 の精度で推定が実現できるといえる．特に歩行〜階段下りという利用者が定常的に動作している状況に限定すると，どの状態もおおよそ 70%の精度を達成している．したがって，利用者が定常的に動作している際は，利用者動作に対して頑健に推定ができているといえる．

表 4.5: 提案手法による 6 状態識別結果

	ポケット	鞄	手持ち	机の上	布団の上	スマホスタンド	Precision
ポケット	25765	1152	273	25	48	15	94.5%
鞄	492	696	11	0	41	72	53.0%
手持ち	1519	531	5535	68	55	98	70.9%
机の上	1	0	0	380	224	0	62.8%
布団の上	47	0	15	136	172	0	46.5%
スマホスタンド	0	39	83	0	61	1018	84.8%
Recall	92.6%	28.8%	93.5%	62.4%	28.6%	84.6%	87.0%

4.3.5　6 状態識別課題における推定精度の考察

以上を踏まえて，最終的に本システム State Magic の 6 状態識別推定精度は表 4.5 となった．これは表 4.3 のポケット 5 種をまとめた結果であるため，処理内容としては 10 状態に識別を行った後にポケット 5 種を結合するという処理となる．推定精度は 87.0%となり高精度で識別ができているといえる．ほかの手法として，識別器を訓練する段階においてポケット 5 種を結合しておく方法も試みたが，推定精度 85.1%となった．誤差の範囲という可能性も検証する必要があるが，今回の実験においては前者を採用する．

表 4.5 のクロス表部分より誤判定パターンに着目する．ポケットを手持ちと誤るパターンがもっとも多かったが，全体数に対して少ないため，再現率に大きな影響は与えていない．次に，鞄をポケットと誤るパターンと，鞄を手持ちと誤るパターンが非常に多く，鞄の再現率が著しく低い結果となった．続いて，手持ちは再現率は高いが，適合率が若干低くなるという結果になった．机の上，布団の上，スマホスタンドの上に着目すると，スマホスタンドの上は再現率適合率ともに高い結果となった．しかし，机と布団を互いに誤るパターンが多く，特に布団の識別率は低い結果となった．

4.4　おわりに

スマートフォンの状況が推定できることで，ポケットの中での誤動作防止や，状態に応じた通知方法の自動変更など，様々なコンシューマサポートが実現できる．その他，利用者の行動認識のため [32] にもスマートフォンの格納場所を推定する技術が必要とされている．

本研究では，加速度センサ，ジャイロセンサ，照度センサ，近接センサを複合的に用いた特徴量を定義し，Random Forest を用いてスマートフォンの 6 状態を識別するシステム

State Magic を提案した．6 状態とはポケットの中，鞄の中，手の中，机の上，布団の上，スマートフォンスタンドの上と定義した．この 6 状態を識別する研究は過去に見られず，類似研究においては歩行状態のみという限定条件があったが，本稿では重力成分のデータを利用することで，利用者の状態に依存しないシステムを目指した点が特徴である．

6 名の被験者の観測データから LOSO-CV で推定精度を評価した結果，以下の知見を新たに示すことができた．

- 重力成分を除いた加速度センサ単体を利用する場合よりも，センサを複合的に用いることで推定精度が向上する．
- 利用者が定常的な動作を行っている状況においては，利用者の動作に依存しない頑健な識別が実現できる．
- 利用者が静止している状況においては，利用者の状況が推定精度に大きく影響を与える可能性がある．
- 目標とした 6 状態識別問題に対しては，87.0%の精度で状況推定ができる．

本稿では，様々な状況において本提案手法を適用した場合の推定精度を測定する実験を実施したが，いくつかの課題が見つかっている．6 状態分類の結果に関しては，利用者が静止している状況での識別精度の低さ，鞄の識別精度の低さ，机と布団の分類ができていない点である．これらの問題に対しては，誤ったパターンのデータを考察し，精度を改善する手法を模索することを今後の課題とする．

また，本稿では特定の状況下における実験データを用いての実験となっていることから，今回対象としなかった状況において識別が困難となることが予想される．例えば，今回実験を行わなかった「自転車で走行している」場合や,「暗い夜道で歩きながらスマートフォンを利用している」場合などが考えられる．前者は自転車走行時の特徴ベクトルを学習させることで推定が可能となるが，後者は照度センサや近接センサをルールベースで処理するほうが高精度を実現できる可能性を考えている．今後は，これらの状況への対応や精度向上を踏まえて，実サービスとして API 公開し効果を検証していきたい．

第 5 章

子供のスマートフォン依存を抑止する画面ロックアプリケーション

5.1　はじめに

近年，世界的にスマートフォンのシェア率が急速に伸びており，利用者の幅も広がっている．幼児期から両親のスマートフォンに触れて育つことも珍しくない．内閣府の平成 25 年度青少年のインターネット利用環境実態調査 [39] によると，自分専用の携帯電話所有率は，小学生で 30.1%，中学生で 48.9%，高校生では 94.5%と示されている．平成 21 年度の同調査 [40] では，小学生で 18.3%，中学生で 43.1%，高校生では 95.4%と示されていることから，ここ数年間での小中学生の携帯電話所有率の伸びが著しいことがわかる．

新しいメディアが普及するとそれに伴う中毒症状を揶揄する表現が現れる．十数年前，インターネットが一般に普及した際より，インターネット依存 [41] という言葉が流行した．インターネット依存だけでなくコンピュータ依存，ゲーム中毒など様々なものがある．最近では携帯電話依存 [42] やスマートフォン依存 [43] という言葉が浸透しつつある．

スマートフォンは小型の PC 並みに機能が充実しており，従来の携帯電話と同様に通話やメールは勿論のこと，PC サイトブラウジングやゲーム，SNS，何十万種類ものアプリケーションなど利用者を飽きさせない．スマートフォンやインターネット技術を使いこなすスキルは，今後必要不可欠になると思われ，子供のころから扱い方やリテラシーを学ぶことは重要である．しかし，これらの技術を利用する際には，過度な利用によって睡眠時間や学習時間の減少，目の疲労など様々な悪影響が起こりうる．総務省情報通信政策研究所の都内高校生を対象とした調査 [44] によると，調査対象者全体の約 6 割がネット依存傾

向中〜高と判定されており，ネット利用の媒体として，スマートフォンやフィーチャーフォンを用いたネット利用の時間が特に長いという結果が出ている．スマートフォンの利用開始によって勉強時間や睡眠時間が減少したと回答した生徒はそれぞれ約 35%，40%となり，実生活への悪影響も危惧されている．その他，インターネット依存とうつ症状や孤独感との関連性の研究や [45]，高校生の携帯電話依存はストレス反応を増悪させることを明らかにした調査研究 [46] も報告されている．

このように様々な悪影響が懸念されるスマートフォン依存症を改善すべく，本研究では，自分でスマートフォンの利用を制御できない子供たちに対し，依存症状の改善をサポートする一改善手法を提案する．また，アンケート分析結果から，本提案手法の効果を評価する．

5.2　関連動向

本章では，インターネット依存やスマートフォン依存に関連する研究，実例を概観し，本研究の立ち位置を明確にする．2015 年現在，スマートフォン依存に関する研究は少ない．そこでインターネット依存や携帯電話依存に関しても同時に調査を行った．

インターネット依存に関する研究としては，インターネット依存 (Internet addiction) という言葉を広めた Young らの研究 [41] が有名である．Young らは論文内でインターネット依存尺度を定義しており，その尺度を用いて実践調査を行った関連研究も多い．日本でも独自の高校生向けインターネット依存傾向測定尺度の開発 [47] が行われている．韓国では特にインターネット依存やスマートフォン依存への関心が強く，韓国向けのインターネット依存尺度として K-scale やスマートフォン依存の尺度として Smartphone addiction scale (SAS) を提唱する研究 [48] もある．最近ではスマートフォンの利用履歴や位置情報を統計的に分析し診断に役立てる技術 [49, 50] も研究されている．

具体的な施策や研究に関して，最も影響範囲の大きい事例は韓国で 2011 年より施行されている「シャットダウン法 (Shutdown law)」である [51]．韓国では 2002 年にインターネットカフェで 24 歳の男性が 86 時間不眠不休でオンラインゲームをプレイし続けた末に急死したなどの事例から，国をあげてインターネット依存対策に取り組んでいる．シャットダウン法は 16 歳未満の青少年に対し，0 時〜6 時までの間は強制的にオンラインゲームの接続を遮断するものである．法令として青少年の自由権や平等権を脅かすのではないかなどの批判もあり，本法令の正当性は議論されているが，国際的にもインターネット依存への

危機感が伺える．日本では，愛知県刈谷市の児童生徒愛護会が，2014 年 4 月より市内の小中学校の生徒・児童に対し，21 時以降はスマートフォンや携帯電話の利用の禁止を各家庭に要請しており [52]，国内の一部でも課題の深刻さを重く受け止め対応を行っていることが伺える．実践的研究としては，鶴田の研究 [53] では，自己の生活のあり方を自律的に改善する力を育てることを目的とする R-PDCA サイクルの手法を取り入れた学習を実践した結果，多くの生徒が携帯電話やパソコンの利用におけるルールの大切さについて肯定的な認識を持ったとしている．

関連動向より，2015 年現在インターネット依存やスマートフォン依存は深刻な問題と受け取られているが，具体的改善策に関する研究は少ない．依存度に関する尺度を定めた研究や，依存尺度を用いて実際に調査を行った研究，依存度合いを自動で推定する研究などがあるものの，診断結果は改善の材料としてあつかうことが多く，工学的な改善手法が少ない．本研究では，画面ロックアプリケーションを用いて，依存症状の改善をサポートする一改善手法を提案し，効果を評価する．ただし，既存のスマートフォン依存尺度上での議論は行わないため，関連研究における尺度を用いていない．提案手法の評価には，提案手法の導入による効果を独自のアンケートから評価する．

5.3　提案手法

スマートフォン依存は，スマートフォンを利用できない時間を作り出し，その生活スタイルに慣れてゆく経験を経ることで依存症状が改善されていくと考えられる．過去のコンピュータ依存やゲーム中毒であれば，依存症状の子供を持つ親は，子供の症状が改善するまで機器を取り上げたり，利用時間の制限を行うなどの物理的対策が容易であった．しかし，携帯電話に関しては物理的に管理することは難しい．文部科学省の平成 21 年子どもの

表 5.1: TIMER LOCK の利用者層と特徴

	導入者	利用者	納得	悪影響の自覚	改善意欲
セルフユーザ	自分	自分	○	◎	◎
チャイルドユーザ	親	自分	○	○	○
フォースドユーザ	親	自分	×	×	×

携帯電話などの利用に関する調査 [54] の 2 章にて，小学 6 年生の携帯電話所有者の 4 割が塾や習いごとを始めたから携帯を持ったという結果が出ている．このように，習い事の際に，連絡手段として小中学生に携帯電話を所有させる親は少なくなく，依存症状の改善対策とはいえ，物理的に取り上げてしまうことは，携帯電話の本来の利点を損なう．そこで，我々の開発する画面ロックアプリケーション TIMER LOCK は，ソフトウェア的手法により携帯電話を使えない時間を実現する．本章では，TIMER LOCK の概要を述べ，研究目的である子供のスマートフォン依存改善への効果的な利用手順の提案と期待される効果に関して説明する．

5.3.1　利用者層の定義

本アプリケーションの利用者をセルフユーザ，チャイルドユーザ，フォースドユーザの 3 種類と定義する．セルフユーザは自分自身でアプリケーションを導入し利用する利用者，チャイルドユーザは親子で相談し，子供が納得した上で親が導入し，子供が利用する利用者，フォースドユーザは子供が納得していないが親が導入し，子供が利用する利用者である．表 5.1 にそれぞれの特徴を定義する．導入者列は TIMER LOCK を導入した人物，利用者列は実際に TIMER LOCK を利用する利用者，納得列は TIMER LOCK の導入に納得しているかを定義している．また，それらの属性を持った 3 種類の利用者層に対して，悪影響の自覚列はスマートフォンによる悪影響の自覚の強さ，改善意欲列はスマートフォン依存改善に対するモチベーションの強さを独自で仮定した．記号は，×＜○＜◎の順で各項目への納得度合いの強さ，悪影響の自覚の強さ，改善意欲の強さを示している．納得具合に関しては，納得しているか否かであるため◎の表現を用いていないが，悪影響の自覚と改善意欲に関しては，セルフユーザよりもチャイルドユーザのほうが強いと思われることから，◎という表現を用いた．

5.3.2　システム概要

TIMER LOCK は事前に設定した時間帯にスマートフォンを利用できないように画面をロックするアプリケーションである．ロック設定時にはパスワードを登録し，ロックの解除やロック時間の変更，アンインストールを行う際に認証を求める．チャイルド・フォースドユーザは親が TIMER LOCK を導入したところですぐにアンインストールしかねないこ

とから，パスワード機能を導入した．セルフユーザは自身でパスワードを把握しているが，解除にパスワードを要するという一手間が入ることで，簡単には解除しなくなる効果を見込んでいる．パスワードは無償版で数値 4 桁，有償版で数値 8 桁まで設定が可能である．

図 5.1 は TIMER LOCK の動作フローであり，図 5.2 は動作画面である．導入者は導入時に図 5.2 の (a) または (b) の画面にて，ロックする時間帯の入力とパスワードの入力を行う．画面 (a) は無償版の，画面 (b) は有償版の設定画面であり，有償版は時間設定に加えて曜日の設定と最大 3 つロック時間を設定できる．TIMER LOCK は常時バックグラウンドで動作し，設定した時間帯に例外画面以外の画面を開いていた場合，図 5.2(c) のロック画面を表示する．ロック画面は通常画面の上にオーバーレイとして表示され，例外画面を除く一切の操作ができなくなる．例外画面は電話発信画面と電話帳画面としている．前述のとおり塾や習いごとを始めたことで子供に携帯をもたせている家庭が少なくないことから，連絡手段用に通話機能のみ利用可能とした．また，チャイルド・フォースドユーザは親世代が導入を行うため，TIMER LOCK はダウンロード，インストールするだけで導入でき，時間とパスワードの設定のみで動作するというシンプルさを重要視した設計とした．TIMER LOCK は Android2.2 以上のプラットフォームに対応しているネイティブアプリであり，現在 Google Play で無償版 [1]，有償版 [2] ともに公開している．

5.3.3　関連製品

2015 年現在，我々の調査にて見つかった幾つかの関連製品の概要を説明する．関連製品は大きく 2 種類に分類することができる．1 種類目はゲーミフィケーションを応用し，自分の意思でスマートフォン依存の改善を促すものである．iPhone，Android に対応している forest[3] では，種を植えてから 30 分間スマートフォンを利用しないことで木が成長する．その間にスマートフォンを利用してしまうと木が枯れてしまう．強制力はなく，自分の意思でスマートフォン依存を改善することをサポートする設計となっている．ほかにもスマートフォンを過度に利用してしまうとロック画面に応援メッセージが現れる Cocaine[4] なども

[1][スマートフォン依存性アプリ タイマーロック Timer Lock]
https://play.google.com/store/apps/details?id=com.has.childlock
[2][スマートフォン依存性アプリ タイマーロック Timer Lock2]
https://play.google.com/store/apps/details?id=com.has.childlockadv
[3][forest] https://play.google.com/store/apps/details?id=cc.forestapp
[4][Cocaine] https://play.google.com/store/apps/details?id=com.taisio.cocaine

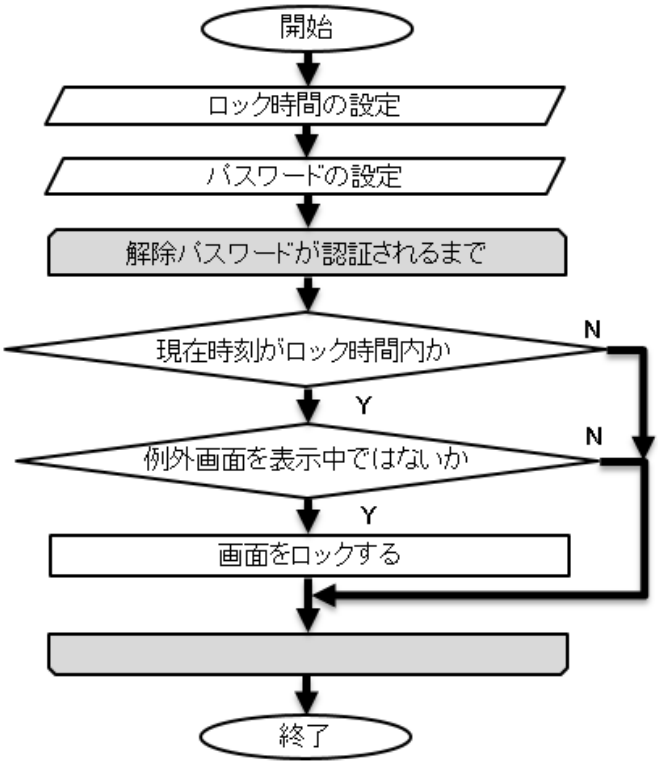


図 5.1: TIMER LOCK の動作フロー

公開されている．2 種類目は強制的にスマートフォンの利用できない時間を作り出すものである．Android に対応しているスマホ依存タイマー [5] は設定した時間が経過するまで画面をロックするアプリである．利用者が 1 時間と設定すると，設定時から 1 時間スマートフォンが使えなくなる．スマホはオワリー [6] ではアプリケーション毎に設定した以上の時間を使い切ると，その日はそのアプリケーションが利用できなくなる．商用アプリケーションでは株式会社ワイエスシーインターナショナルよりスマモリ [7] が，デジタルアーツ株式会社から i-フィルター [8] がライセンス販売されている．これらのアプリでは親が設定した時間帯に画面をロックする機能や有害コンテンツのブロック，利用アプリの監視機能などが実装されている．

本研究では自身でスマートフォン依存を抑制できない子供たちを対象としているため，後者のスマートフォンを利用できない時間を作る方針を採用した．また，自身で導入するセルフユーザだけでなく，子供に導入するチャイルドユーザも対象としているため，パス

[5][スマホ依存タイマー] https://play.google.com/store/apps/details?id=jp.s122107.phonescreentimer
[6][スマホはオワリー] https://play.google.com/store/apps/details?id=jp.co.evoltech.apptimer
[7][スマモリ] http://smamori.jp/
[8][i-フィルター] https://play.google.com/store/apps/details?id=jp.co.daj.consumer.ifilter

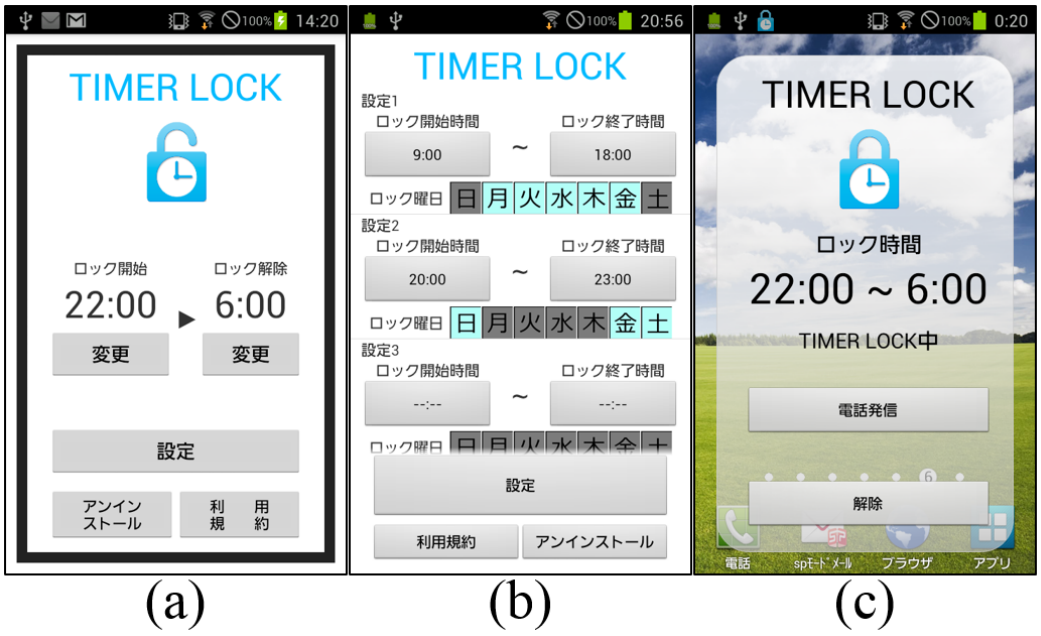


図 5.2: TIMER LOCK 操作画面: (a) 無償版設定画面 (b) 有償版設定画面 (c) ロック中のホーム画面

ワード機能を持たせ，かつシンプルにスタンドアローンで完結する仕組みとした．

ここで，時間ロックを実現する手法は 3 種類存在している．1 つ目はスマホ依存タイマーにて採用されている方式で，開始時から一定時間をロックする方法である．これは一時的に集中したい時に利用でき，セルフユーザに短期的効果を発揮するが，毎回自分で開始する必要があるため，スマートフォン依存を長期的に改善するには向いていない．2 つ目はスマホはオワリーで採用されている方式で，アプリケーション毎に上限時間を設定するものである．とあるアプリを 1 日 1 時間と設定することで，1 時間プレイするとアプリが強制終了するというものである．この方式は子供が自分で遊ぶ時間をやり繰りし，計画してスマートフォンを利用する力を育むサポートができる．3 つ目はスマモリや i-フィルターで採用されている方式で，事前に設定した時間帯にスマートフォンが利用できなくなるものである．0 時～7 時と設定しておくことで寝る時間のスマートフォン利用を制限することなどが可能になる．

本研究では生活習慣の改善なども期待することから，3 つ目の方式を採用した．また，その中でも子供の自主性，計画性を育むことを意識し，特定のアプリケーションブロック機能や，利用アプリの監視機能は実装していない．これらの機能はより強固にスマートフォンの利用を制限できるが，親側に強すぎる権限を与えることは子供の自由やプライバシー

を侵害しすぎることが懸念される．TIMER LOCK では時間帯のみを制限要項とし監視機能をなくすことで，子供はロック外の時間で自由に計画してスマートフォンを利用することができ，プライバシーも侵害しない．

5.3.4　利用シーンの提案

スマートフォン依存を改善する手法は様々だが，本研究ではその中の一手法として TIMER LOCK を用いた改善手法を以下に提案する．

表 5.1 にまとめたように，セルフユーザはスマートフォン依存の悪影響を自覚し，改善のモチベーションを持って自分でアプリケーションを導入した利用者層である．自分の意志だけではスマートフォンを利用してしまうことから TIMER LOCK のような強制力のあるアプリケーションを選択したと推測できる．本研究では，彼らはスマートフォンを気にしすぎる生活の改善や，無駄にスマートフォンに奪われている時間を取り戻すことを短期目標としていると仮定する．最終到達目標は TIMER LOCK がない状態でも自身で利用時間をコントロールできるようになることであると仮定する．そのための効率的な利用方法として次のプロセスを提案する．(1) 改善目標を一つ以上定義し，それに対するロック時間を設定する．例えば睡眠不足を改善目標とするのであれば，0 時〜7 時をロック時間とする．(2)1 週間程度利用した後に，改善の実感度合いや自分のストレス具合に応じてロック時間の見直しを行う．(3) ロック時間を大幅に短くできるようになってきた際には，TIMER LOCK の利用を中止するか，5.3.3 節の関連製品で紹介したようなゲーミフィケーションを用いたサポート方針に切り替えを行い，より自制心を鍛えられるようにトレーニングする．セルフユーザはパスワードを把握しているため，ロックを解除することは難しくない．そのため，ロックを一時的に解除してしまった回数をカウントしモチベーションとする方法や，無意味な数値の羅列をパスワードとし，自身でも解除できなくしてしまうという方法も効果的である．

チャイルドユーザは親子が同意の上で導入する利用者であり，フォースドユーザは親に強引に導入された利用者である．チャイルドユーザに対しフォースドユーザはスマートフォン依存の改善意欲が低いと考えられる．そのため，ロック中のスマートフォン利用は制限されるが，ロック中以外でスマートフォン利用時間が増加してしまうことや，子供が親に強く反感を持ってしまうことなどが懸念される．これでは子供のストレスを増加させるだ

けで，スマートフォン依存が改善されたとは言いがたい．本手法はフォースドユーザを対象とせず，子供に利用させる場合は，しっかりと親子で相談を行い，スマートフォン依存の悪影響や危険性に関する教育を行った上で，子供を納得させてから利用させる手法を提案する．相談，教育を経ても子供が納得しない場合は TIMER LOCK ではない別の手法にてスマートフォン依存を改善することを推奨する．チャイルドユーザに対する効率的な利用方法として次のプロセスを提案する．(1) 改善目標を一つ以上設定し親子で共有する，それに対するロック時間を設定する．(2) 定期的に親が子の改善度合いを評価し，それに応じたロック時間の微調整を行う．(3)TIMER LOCK がなくとも改善目標が達成できると判断できる状態になり次第 TIMER LOCK の利用を中止するか，5.3.3 節の関連製品で紹介したようなゲーミフィケーションを用いたサポート方針に切り替える．セルフユーザとプロセスは大きく変わらないが，親が適切に子供に関与していく点が特徴である．

本研究では，以上の利用シーンを理想的な利用シーンとして提案する．中でも，提案手法の肝となる部分は，親が子に導入するケースにおいて，親と子が話し合い，同意を得た上で導入を行うという点である．本研究の評価は，アプリケーションの理想的な手法を強要せず，様々な利用者に，様々な利用シーンにて自由に利用させ，その結果をアンケートから考察する．特に，提案の肝である親子の同意の有無に焦点を当て，セルフユーザ，チャイルドユーザ，フォースドユーザ間での効果の差を考察する．次節では TIMER LOCK によって期待される効果を述べ，章を跨ぎ，評価手法の詳細を述べる．

5.3.5　期待される効果

TIMER LOCK の導入により，利用者には (1) 余裕時間の増加，(2) 集中の妨害要素の排除 (3) 生活習慣や健康の改善などの効果を期待している．(1) に関して，過度にスマートフォンに熱中していた利用者も，強制的に利用できない時間が設けられることによって，空白の時間を作る効果がある．空いた時間には，勉強や睡眠，ほかの遊びをしてもよい．利用者に新しい時間の使い方を考える切っ掛けを与えることができる．(2) に関して，スマートフォンに多い SNS の通知やメールの通知から利用者の集中状態を守る効果が期待できる．通知が来ても内容を確認できないため利用者は諦めがつき，より物事へ集中できる．(3) に関して，深夜帯にロック時間を設定することで睡眠時間を確保でき，生活リズムの改善に繋がる．また，スマートフォン利用時間が減少すると目への負担も軽減できる．最終的に

は，これらのポジティブな効果がスマートフォン依存の改善に繋がると見込んでいる．

5.4　評価と考察

5.4.1　評価アンケート

TIMER LOCK 無償版では利用時にアンケートの回答を任意で募っている．アンケート（表 5.2）はロック開始から 10 日後にスマートフォン所有者に対して実施するアンケートである．TIMER LOCK 無償版では 2014 年 6 月アップデート時以降 6ヶ月で 386 件のアンケート回答を得ている．本章では，アンケート結果の分析を通じて，利用者属性に関する考察と，提案手法の効果の評価を行う．提案手法の効果を正確に評価するには 5.3.4 節にて提案した理想的な利用シーンに従った人と従っていない人の間で効果を比較することが望ましいが，利用者が効率的な利用方法に従ったか否かを判断することは難しい．本稿では提案の肝である親子の同意の有無に焦点を当て，セルフユーザ，チャイルドユーザ，フォースドユーザの間で効果の比較を行うことで提案手法の評価を考察する．提案手法にて重要視した “親子での相談と同意” を実施したチャイルドユーザと，親が強制しているフォースドユーザにおいて，TIMER LOCK の効果を比較することで提案手法の重要性を示す．

5.4.2　利用者属性に関する分析

始めに各利用者属性の回答者数と年齢を明らかにする．アンケート Q1（TIMER LOCK は自分の意志でインストールしましたか），Q15（よろしければ年齢を教えてください），Q16（よろしければ性別を教えてください）の結果から回答者の人数分布と平均年齢を表 5.3 に示す．ここで，平均年齢列は各利用者層毎の平均値を算出しているが，年齢を未記入とした利用者と性別を秘密と回答した利用者は欠損値として除外して計算している．また，以降は Q1 をその他と回答した利用者と性別を秘密と回答した利用者を欠損値として除外し，310 件の回答をもとに考察を進める．図 5.3 は導入者別の回答者年齢ヒストグラムである．

表 5.3 より，導入者に着目すると，自分で導入した利用者（セルフユーザ）205 名（56.5%）のほうが，親が導入した利用者（チャイルドユーザ＋フォースドユーザ）158 名（43.5%）より多い回答があった．親が導入した利用者の中で，親子で納得の上で導入した比率に着

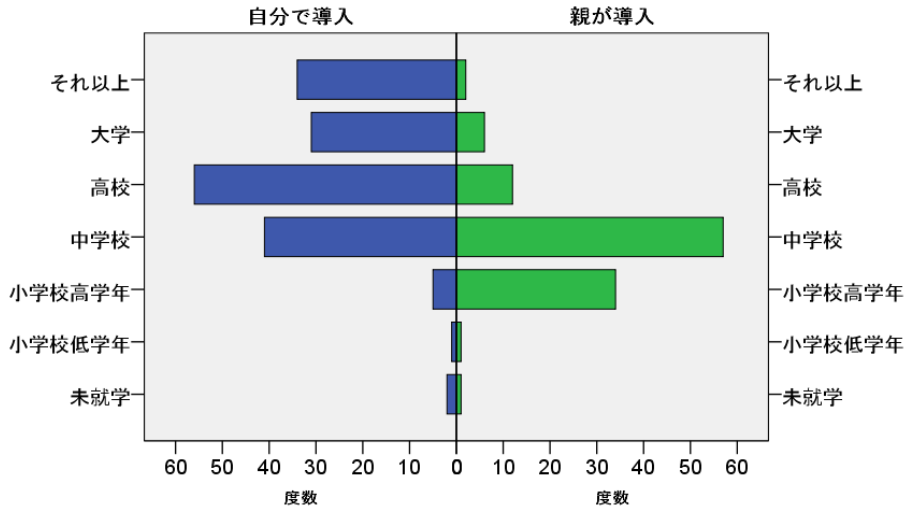


図 5.3: 導入者別の利用者年齢分布

目すると，納得している利用者（チャイルドユーザ）84 名（53.2%）のほうが，納得していない利用者（フォースドユーザ）74 名（46.8%）より多く回答があった．男女比に着目すると，全体では男性 171 名（55.2%）のほうが，女性 139 名（44.8%）より多く回答があった．ここで，利用者層と性別の独立性に着目し，有意水準 5%でカイ二乗検定を実施したところ，セルフユーザ，チャイルドユーザ，フォースドユーザ間でそれぞれ有意差は見られなかった．平均年齢に着目すると，セルフユーザでは 20.7 歳，チャイルドユーザでは 14.0 歳，フォースドユーザでは 14.2 歳となった．図 5.3 をみると，セルフユーザは高校生の利用者が最も多く，中学生や大学生以上の利用者も多く存在しているが，チャイルド・フォースドユーザは中学生の利用者が最も多く，次いで小学校高学年の利用者が多い傾向が見られた．

続いて，5.3.1 節で定義した利用者層の “悪影響の自覚” と “改善意欲” が表 5.1 の仮定を満たすかを考察する．アンケートの，Q11（スマホを使い始めて，健康や精神的な弊害が出たと思いますか）を悪影響の自覚具合として考察する．ただし，アンケート項目に，改善意欲を図るものがなかったため，Q7（TIMER LOCK を利用してみてよかったと思いますか）で良かったと回答している利用者は改善意欲有りと仮定して考察を行った．

Q11 の結果（表 5.4）より，スマートフォン利用により健康や精神的弊害を実感している利用者の比率は全体で 44.2%となった．男女間の回答率の差に着目し，カイ二乗検定を実施したところ有意差は見られなかった（p=0.921）．続いて，利用者層による回答率の差に着目し，セルフユーザとチャイルドユーザ間，チャイルドユーザとフォースドユーザ間でそ

れぞれカイ二乗検定を実施したところ，どちらも有意差が見られた（p=0.000，p=0.001）．したがって，スマートフォンによる弊害を実感していると回答する比率は性別に従属しないものの，利用者層には有意な回答率の差が見られ，セルフユーザ＞チャイルドユーザ＞フォースドユーザの順でスマートフォン利用による弊害を実感している率が低くなることがわかる．これより，表 5.1 の “悪影響の理解” の定義と一致していることを確認した．ここで，年齢による影響を確認するため，回答を “12 歳まで”，“15 歳まで”，“それ以上” に分類し，自分で導入した利用者群と親が導入した利用者群それぞれにおいてカイ二乗検定を実施したところ有意差が見られなかった（p=0.064，p=0.991）．

Q7 の結果（表 5.5）より，TIMER LOCK を利用してよかったと回答した利用者の比率は全体で 74.8%となった．以下同様の検定を実施したところ，男女間の回答に有意差は見られず（p=0.594），セルフユーザとチャイルドユーザ間，チャイルドユーザとフォースドユーザ間ではどちらも有意差が見られた（p=0.000，p=0.000）．したがって，こちらも Q11 と同様の結果となり，TIMER LOCK を利用してよかったと回答する比率は性別に従属しないものの，利用者層には有意な回答率の差が見られ，セルフユーザ＞チャイルドユーザ＞フォースドユーザの順で TIMER LOCK を利用してよかったと感じている率が低くなることがわかる．これより，表 5.1 の “改善意欲” の定義と一致していることを確認した．ここで，年齢による影響を確認するため，回答を “12 歳まで”，“15 歳まで”，“それ以上” に分類し，自分で導入した利用者群と親が導入した利用者群それぞれにおいてカイ二乗検定を実施したところ有意差が見られなかった（p=0.087，p=0.545）．

5.4.3　TIMER LOCK の効果

5.3.5 節では，TIMER LOCK の導入により (1) 余裕時間の増加，(2) 集中の妨害要素の排除，(3) 生活習慣や健康の改善などの効果を期待していると述べた．本節では，(1) とその余裕時間の使い方に関する考察を行い，次に，(2)，(3) をアンケート内の自由記述から考察する．

余裕時間の変化

TIMER LOCK 導入前後の余裕時間の増加を確かめるため，スマートフォン利用時間の変化を考察する．スマートフォン利用時間が減少することで，空いた時間が生まれ，余裕

時間の増加につながると考えられる．アンケート Q3，Q4 ではそれぞれ TIMER LOCK 導入前後でのスマートフォン利用時間について尋ねており，両回答間にてスマートフォン利用時間が減少したか，変わっていないか，増加したかに分類した．その結果，増加した利用者は 310 名中 7 名となり，増加の期待度数が小さすぎるため，不変と増加をあわせて検定を行った．表 5.6 は減少した利用者の比率を集計している．なお，選択肢の最小値が 1 時間のため，Q3 で 1 時間と回答していた利用者 44 名は減少になりえず不変になりやすいことを注意されたい．

表 5.6 より，TIMER LOCK 導入後スマートフォン利用時間が減少したと回答した利用者の比率は全体で 60.0%となった．また，カイ二乗検定にて男女間で有意差が見られた（p=0.045）ため，女性チャイルドユーザに着目すると，78.6%がスマートフォン利用時間が減少しており，ほかと比べ高い比率となっていることがわかる．したがって，女性チャイルドユーザとその他に有意差があると仮定し，男性チャイルドユーザと女性チャイルドユーザ間でカイ二乗検定を実施したところ有意差が見られた（p=0.013）．それに対し，セルフユーザやフォースドユーザにて同様の検定を実施したところ，どちらも有意差が見られなかった（p=0.444，p=0.697）．したがって，女性のチャイルドユーザは特徴的にスマートフォン利用時間が減少したと回答している率が高いことがわかる．また，セルフユーザとチャイルドユーザ，セルフユーザとフォースドユーザ間でそれぞれカイ二乗検定を実施したところ前者で有意差は見られず，後者で有意差が見られた（p=0.547，p=0.006）．したがって，全体としてセルフユーザ≒チャイルドユーザ ≥ フォースドユーザの順で TIMER LOCK 導入後にスマートフォン利用時間が減少した率が低くなり，効果の発揮され易さに差がでていることがわかる．ここで，年齢による影響を確認するため，回答を “12 歳まで”，“15 歳まで”，“それ以上” に分類し，自分で導入した利用者と親が導入した利用者それぞれにおいてカイ二乗検定を実施したところ有意差が見られなかった（p=0.977，p=0.686）．

余裕時間中の行動

TIMER LOCK にてスマートフォンが利用できない時間帯に利用者はどのような行動を取るのかを考察する．アンケート Q5（TIMER LOCK で画面がロックされている時間に何をしていますか）と Q6（TIMER LOCK により勉強時間は 1 日何分くらい増加しましたか）をそれぞれ表 5.7 と表 5.8 に集計した．表 5.7 より，全体として勉強と回答した利用者が最も多く 51.6%となり，次いで睡眠が 16.8%となった．男女間で見ると，女性のほうが

勉強や睡眠の回答率が高く，男性のほうがその他の回答率が高い結果となった．利用者層で見ると，セルフユーザの勉強の回答率がほかに比べて圧倒的に高く65.0%となった．

回答率の高かった勉強時間に焦点を当てた表5.8に関して，全体では63.9%が1日30分以上勉強時間が増加したと回答している．ここで，期待度数が小さすぎる項目が多いため，“変わらない”，“30分〜1時間”，“2時間以上”に再分類して検定を行った．男女間でカイ二乗検定を実施したところ有意差が見られなかった（p=0.195）．続いて，セルフユーザとチャイルドユーザ間，チャイルドユーザとフォースドユーザ間でカイ二乗検定を実施したところ前者は有意差が見られ，後者は有意差が見られなかった（p=0.013，p=0.086）．したがって，勉強時間の増加は性別に従属しないものの，利用者層には有意な回答率の差が見られ，セルフユーザ＞チャイルドユーザ≒フォースドユーザの順で勉強時間の増加率が低くなることがわかる．ここで，年齢による影響を確認するため，回答を“12歳まで”，“15歳まで”，“それ以上”に分類し，自分で導入した利用者群と親が導入した利用者群それぞれにおいてカイ二乗検定を実施したところ，前者は有意差が見られず，後者は有意差が見られた（p=0.864，p=0.048）．親が導入した利用者群は年齢像が低いことからも，特に勉強時間の増加に年齢が影響しやすい可能性を示している．

その他の効果

その他の効果として，5.3.5節で述べた(2)集中の妨害要素の排除，(3)生活習慣や健康の改善などの効果を含めて自由記述から考察する．アンケート内で実施している自由記述は，TIMER LOCKを利用して良かったかに対する理由を問うQ8と，「その他ご意見ご要望などありましたらご記入ください」と尋ねるQ18である．両方あわせて207件のコメントがあり，回答率は33.4%となった．内訳はポジティブな感想が98件，ネガティブな感想が40件，どちらでもない感想が37件，要望が32件であった．ポジティブな感想に着目すると，生活が改善されたなどの回答が24件，勉強時間が増加したという回答が21件，勉強などに集中できるという回答が19件，睡眠時間が確保できたという回答が9件，スマートフォン利用時間が減少したという回答が9件，その他が16件となった．このことから，期待される効果(2)(3)が一部の利用者にて確認できる．

ネガティブな感想としては，TIMER LOCKを使って良かったと思わないと回答した利用者がその理由を述べる傾向が多く見られた．内容に着目すると，〇〇の機能が使えないからという回答が8件，自由が奪われたからという回答が7件，意志が弱く結局誘惑に勝

てないからという回答が6件，携帯をもっと使いたいからという回答が5件，友人との連絡中に使えないことがあるからという回答が4件，ストレスが溜まるからという回答が3件，暴言やその他の意見が7件となった．利用者層別の内訳は，セルフユーザが7件，チャイルドユーザが7件，フォースドユーザが26件と，親子で相談せずに導入したフォースドユーザからの意見が特に多かった．

5.5　まとめ

本研究では，スマートフォン依存に対する一手法として，親子で相談を行って画面ロックアプリケーションを導入し，スマートフォン依存改善を進めてゆく手法を提案し，アンケートから評価を行った．開発した画面ロックアプリケーション「TIMER LOCK」は設定した時間帯に通話以外の機能を使えなくするアプリケーションである．現在無償版公開から半年以上経過し，Google Play より総ダウンロード数10,000以上，総レビュー数146件，レビュー平均値3.1との評価を得ている．アプリケーションの利用者は，自分で導入したセルフユーザ，親と相談し納得した上で導入したチャイルドユーザ，納得していないが親が導入したフォースドユーザという3種類の利用者層を定義してアンケートの分析を行った．その結果，セルフユーザ＞チャイルドユーザ＞フォースドユーザの順で，スマートフォンによる悪影響を自覚している率が低くなり，本アプリケーションを利用して良かったと回答する比率も低くなるなどの利用者傾向を示した．さらに，スマートフォン利用時間の減少者率，空いた時間を勉強に使っている回答者率，勉強時間が増加した回答者率を分析したところ，セルフユーザ≥チャイルドユーザ≥フォースドユーザの順で効果が低くなる傾向を示した．それに対し，ほとんどの項目の回答率は性別や年齢による有意差が見られなかった．このことから，性別や年齢によらず，利用者層によって TIMER LOCK の導入効果に差が出ることを明らかにした．特に，提案手法である “親子で相談，同意” をしているチャイルドユーザのほうが，強制的に親に導入されたフォースドユーザよりも効果が高いことから，提案手法の重要性を示した．

アンケート結果の全体を見ると，6割の利用者にてスマートフォン利用時間の減少を確認した．空いた時間には勉強をしていると回答した利用者が全体で5割程度になり，勉強時間が増加したと回答した利用者も6割を超えた．これらより，各利用者の短期的なスマートフォン依存改善効果は確認できたと考えている．TIMER LOCK を導入することで，利用

者に新しい時間の使い方を考える切っ掛けを与え，その生活に馴染んできた時に，TIMER LOCK を使わずともスマートフォンの利用を自制することができるようになっていれば，完全に依存状態を脱せたといえるだろう．

本研究では，TIMER LOCK を開発し，理想的な利用シーンの提案を行い，特に重要視した “親子間での同意” という点に焦点を当てた提案手法の効果を評価した．今後は，理想的な利用シーンを推奨するような説明文の明記や，アプリ導入時のチュートリアルの開発を行い，理想的な利用シーンに従った場合の効果も検討していきたい．その他，長期的なアンケートや動作ログの分析から，短期的な改善効果だけでなく，長期的な影響や効果の分析や，今回現れた男女差，年齢差に対する標本サイズを増やした考察を行っていきたい．また，親子間で納得して利用することを前提としているとはいえ，全体の 25%程度の利用者がフォースドユーザであった．本アプリケーションは子供の自由を制限することを目的としていないため，今後のアップデートにてフォースドユーザに対する緩和措置などの工夫も検討していく必要がある．また，コミュニケーションツールの強制切断に対する対応や，セルフユーザへの強制力向上の工夫なども考えていく必要がある．それら工夫による改善効果に関する分析も行っていきたい．

表 5.2: アンケートの内容

ID	質問文	選択肢
Q1	TIMER LOCK は自分の意志でインストールしましたか	0) 自分の意志 1) 親の意志（納得はしている） 2) 親の意志（納得していない） 3) その他
Q2	自分の意志ではスマートフォンの利用が止められなくなる時がありますか	0) よくある 1) たまにある 2) あまりない 3) 全くない
Q3	TIMER LOCK を利用する前は 1 日何時間程度スマートフォンを利用していましたか	0)1 時間 1)2 時間 2)3 時間 3)4 時間 4)5 時間以上
Q4	TIMER LOCK を利用してみて 1 日何時間程度スマートフォンを利用するようになりましたか	0)1 時間 1)2 時間 2)3 時間 3)4 時間 4)5 時間以上
Q5	TIMER LOCK で画面がロックされている時間に何をしていますか	0) 勉強 1) 家事 2) 家族とのコミュニケーション 3) 睡眠 4) ゲーム 5) 漫画 6) 他の遊び 7) その他
Q6	TIMER LOCK により勉強時間は 1 日何分くらい増加しましたか	0) 変わらない 1)30 分 2)1 時間 3)2 時間 4)3 時間 5)4 時間以上
Q7	TIMER LOCK を利用してみてよかったと思いますか	0) 思う 1) 思わない
Q8	その理由はなんですか	(自由記述)
Q9	スマホの利用は，健康や精神へ悪影響があると思いますか	0) はい 1) いいえ
Q10	どのような影響があると思いますか	0) 目が悪くなる 1) 勉強時間が減る 2) 成績が下がる 3) 集中力が低下する 4) 会話が減る 5) 体調を崩す 6) 外出が減る 7) 睡眠時間が減る 8) その他
Q11	スマホを使いはじめて，健康や精神的な弊害が出たと思いますか	0) はい 1) いいえ
Q12	どのような影響が出ましたか？	0) 目が悪くなった 1) 勉強時間が減った 2) 成績が下がった 3) 集中力が低下した 4) 会話が減った 5) 体調を崩した 6) 外出が減った 7) 睡眠時間が減った 8) その他
Q13	スマホの長時間利用により，辛さを感じたことは有りますか	0) はい 1) いいえ
Q14	どのようなことに辛さを感じましたか	0) 目や頭が痛くなる 1) 友達づきあいが面倒 2)SNS の返信が面倒 3) メールの返信が面倒 4) 睡眠時間の減少 5) その他
Q15	よろしければ年齢を教えてください	年齢：(自由記述)
Q16	よろしければ性別を教えてください	0) 男 1) 女 2) 秘密
Q17	よろしければ偏差値を教えてください	偏差値：(自由記述)
Q18	その他ご意見ご要望などありましたらご記入ください	(自由記述)

表 5.3: 利用者層別の回答者数と平均年齢

回答者数	男性	女性	秘密	総計	平均年齢 (SD)[歳]
セルフユーザ	93	84	28	205	20.7(± 11.37)
チャイルドユーザ	41	28	15	84	14.0(± 4.7)
フォースドユーザ	37	27	10	74	14.2(± 5.0)
その他	8	7	8	23	20.0(± 10.0)
総計	179	146	61	386	18.2(± 9.9)

表 5.4: 利用者層別の Q11（スマホを使い始めて，健康や精神的な弊害が出たと思いますか）の “はい” の回答率

回答率（“はい” の回答数/総回答数）	男性	女性	合計
セルフユーザ	63.4% (59/93)	59.5% (50/84)	61.6% (109/177)
チャイルドユーザ	31.7% (13/41)	32.1% (9/28)	31.9% (22/69)
フォースドユーザ	10.8% (4/37)	7.4% (2/27)	9.4% (6/64)
合計	44.4% (76/171)	43.9% (61/139)	44.2% (137/310)

表 5.5: 利用者層別の Q7（TIMER LOCK を利用してみてよかったと思いますか）の “はい” の回答率

回答率（” はい” の回答数/総回答数）	男性	女性	合計
セルフユーザ	93.5% (87/93)	91.7% (77/84)	92.7% (164/177)
チャイルドユーザ	78.0% (32/41)	71.4% (20/28)	75.4% (52/69)
フォースドユーザ	29.7% (11/37)	18.5% (5/27)	25.0% (16/64)
合計	76.0% (130/171)	73.4% (102/139)	74.8% (232/310)

表 5.6: 利用者属性別の TIMER LOCK 導入前後でスマートフォンの利用時間が減少した回答者の比率

回答率（“減少” の回答数/総回答数）	男性	女性	合計
セルフユーザ	62.4%　(58/93)	67.9%　(57/84)	65.0%　(115/177)
チャイルドユーザ	48.8%　(20/41)	78.6%　(22/28)	60.9%　(42/69)
フォースドユーザ	43.2%　(16/37)	48.1%　(13/27)	45.3%　(29/64)
合計	55.0%　(94/171)	66.2%　(92/139)	60.0%　(186/310)

表 5.7: TIMER LOCK 導入後の実際の行動に関するロック中の行動 [回答者数（比率）]

	勉強	家事	家族とのコミュニケーション	睡眠	ゲーム	漫画	ほかの遊び	その他	合計
合計	160(51.6%)	13 (4.2%)	17 (5.5%)	52 (16.8%)	15 (4.8%)	5 (1.6%)	15 (4.8%)	33 (10.6%)	310(100.0%)
男性	83 (48.5%)	8 (4.7%)	11 (6.4%)	21 (12.3%)	12 (7.0%)	4 (2.3%)	9 (5.3%)	23 (13.5%)	171(100.0%)
女性	77 (55.4%)	5 (3.6%)	6 (4.3%)	31 (22.3%)	3 (2.2%)	1 (0.7%)	6 (4.3%)	10 (7.2%)	139(100.0%)
セルフユーザ	115(65.0%)	6 (3.4%)	10 (5.6%)	25 (14.1%)	3 (1.7%)	1 (0.6%)	4 (2.3%)	13 (7.3%)	177(100.0%)
チャイルドユーザ	25 (36.2%)	5 (7.2%)	5 (7.2%)	13 (18.8%)	5 (7.2%)	1 (1.4%)	6 (8.7%)	9 (13.0%)	69 (100.0%)
フォースドユーザ	20 (31.3%)	2 (3.1%)	2 (3.1%)	14 (21.9%)	7 (10.9%)	3 (4.7%)	5 (7.8%)	11 (17.2%)	64 (100.0%)

表 5.8: TIMER LOCK 導入後の一日の勉強時間の増加 [回答者数（比率）]

	変わらない		30 分		1 時間		2 時間		3 時間		4 時間以上		合計	
合計	112	(36.1%)	57	(18.4%)	73	(23.5%)	33	(10.6%)	12	(3.9%)	23	(7.4%)	310	(100%)
男性	64	(37.4%)	32	(18.7%)	44	(25.7%)	13	(7.6%)	5	(2.9%)	13	(7.6%)	171	(100%)
男性	48	(34.5%)	25	(18.0%)	29	(20.9%)	20	(14.4%)	7	(5.0%)	10	(7.2%)	139	(100%)
セルフユーザ	54	(30.5%)	32	(18.1%)	42	(23.7%)	23	(13.0%)	9	(5.1%)	17	(9.6%)	177	(100%)
チャイルドユーザ	27	(39.1%)	18	(26.1%)	17	(24.6%)	5	(7.2%)	1	(1.4%)	1	(1.4%)	69	(100%)
フォースドユーザ	31	(48.4%)	7	(10.9%)	14	(21.9%)	5	(7.8%)	2	(3.1%)	5	(7.8%)	64	(100%)

第 6 章

結論

本論文では，スマートフォンの標準搭載センサや機能から得られる多大なる情報を活用することで，スマートフォンの操作性改善や，さらには利用者自身の行動改善への応用を行った．スマートフォンの操作性を改善するために，画面のロックや，音量設定の自動化，スマートフォンの状況推定を実現した．スマートフォン標準搭載のセンサや操作ログを活用し，機械学習を行うことで，従来実現できていなかったインテリジェントな機能を実現することができた．また，スマートフォンアプリケーションを教育に応用する事例として，スマートフォン依存改善のための画面ロックアプリケーションを開発し，大規模な実証実験を行い，効果の検証評価を実施した．

2 章では，近接センサを用いた画面自動ロックシステムを開発し，誤判断の改善を行った．単純な近接ロックでは，意図しないタイミングで画面がロックされてしまう「誤判断」が多く発生し，操作性が悪くなってしまう．利用者の使い方によって，誤判断は表示中の画面に依存する可能性を考え，過去の誤判断を機械学習によって学び，誤判断を低減する手法を提案した．精度評価実験の結果，なにもしない場合に比べて圧倒的に誤判断を低減することに成功した．また，ディレイという近接センサの反応時間に応じた誤判断低減手法と比べても，若干の精度向上を見せた．

3 章では，日々の設定を学習するスマートフォンのアプリ音量自動切り替え手法を提案し，評価を実施した．9 名に対する小規模実験を実施した結果，マナーモードを定期的に切り替えている利用者が 1 名，アプリ音量を定期的に切り替えている利用者が 5 名となり，全体の需要を調査する必要性があると考えた．低消費電力で取得できるスマートフォンログを大規模に収集する実験を行い，需要の分析を行った結果，約半分程度の利用者が 1 周間に 5 日以上マナーモードや音量を変更して運用していることを確認し，本システムの需

要はあると判断した．本研究では，低消費電力で取得できるスマートフォンログから，機械学習によって利用者の定期的な設定を学習するシステムを提案した．提案手法では，スマートフォンログから画面遷移毎にインスタンスを生成し，アプリ音量がオンかオフかを推定する機械学習を行う．その過程で，例外的なインスタンスを除外することにより，定期的な設定を抽出することに成功した．アプリ音量を頻繁に切り替えている 107 名を対象に推定精度を評価した結果，最終的に 86.0%の利用者に対し，有効性を確認することに成功した．

4 章では，コンシューマサポートに向けたスマートフォンの所在推定システムを提案し，評価を実施した．スマートフォンの所在がわかることで，所在に応じた通知方法の変更や，スマートフォンの誤作動防止などのコンシューマサポートが実現できる．提案手法では，加速度センサの加速度成分，重力成分，ジャイロセンサ，照度センサ，近接センサを複合的に利用し，機械学習によってスマートフォンの所在を 6 状態から推定する．6 状態はポケットの中，鞄の中，手の中，机の上，布団の上，スマホスタンドの上としている．各センサ各軸の観測値から，付録の表 1 に示す 506 次元の特徴を観測し，Random Forest にて特徴選択を行った上で 6 状態を識別している．6 名の被験者に対し 165 パターンのタスクを各 20 秒実施した結果の分析を行った．その結果，加速度センサの加速度成分単体を用いるのに対し，様々なセンサを複合して用いたほうが推定精度が 10.2%向上すること，利用者が定常的な動作を行っている際は動作によらず頑健に所在推定が実現できていること，最終的な推定精度 87.0%となることなどを示した．

5 章では，子どもたちのスマートフォン依存症を改善するための画面ロックアプリケーションを開発し，広く普及し，効果の検証を行った．画面ロックアプリケーションとは，事前に設定した時間帯にてスマートフォンを通話以外利用できなくするアプリケーションである．自分で利用するケース，親が導入するケースを想定し，ロック設定はパスワードで管理している．提案手法として，親が導入する場合は子どもと相談し納得した上で導入を行うこととしている．アプリケーションを一般公開した結果，半年で約 10000 ダウンロードを達成し，1 年で 20000 ダウンロードを達成している．利用開始から 10 日後に任意でアンケートを行っており，310 件の有効回答からアプリケーションの効果と提案手法の影響を分析した．統計的検定を実施した結果，自分で導入した利用者＞納得した上で親が導入した利用者＞親が強制的に導入した利用者の順でスマートフォン依存の改善効果が弱くなるということがわかった．また，同様の順にしたがって，スマートフォン依存に対する危

機感や改善意欲が低くなることも示した．また，全体として導入後にスマートフォン利用時間が増加した利用者はほぼおらず，約 60%の利用者にてスマートフォン利用時間が減少したとの結果も得られた．

以上のように，本研究では近年急速に普及しているスマートフォンを対象に，操作性の改善や利用者の行動改善に取り組んできた．機械学習のテクニックを応用し，設定を自動化することや所在の推定などを通じて，スマートフォン自体の操作性の改善を実現できたこと，アプリケーションを開発し，スマートフォン依存症という子供たちの行動改善を実現できたことを本研究の成果として本論文のまとめとする．

本論文ではそれぞれの課題に対して，我々の提案手法が有意に働くことを示してきた．しかし，それぞれにおいて，特徴量生成手法の改良や機械学習アルゴリズムの改良，実験で得られたデータから誤りパターンの考察などにより，より高精度でより有用性の高いシステムを実現していく．これらの研究で培ってきたコンテキストアウェアネスに関する応用技術を，現実のほかの課題に対して応用し，スマートフォンの操作性改善に努めていくことを今後の課題とする．また，スマートフォンが便利になるにつれて，スマートフォン依存症に陥る子どもたちも増えていくことが懸念される．我々の開発したアプリケーションは現在も公開されており，ダウンロード数も増加している．今後もアンケートや操作ログの分析を通じて，本アプリケーションの効果の分析を続けるとともに，アプリケーションの改良や新規開発を経て，スマートフォン依存改善に取り組んでいくことを今後の課題とする．

謝辞

本論文をまとめるに辺り，終始暖かい激励，ご指導，ご鞭撻を賜りました，金沢大学理工研究域電子情報学系教授の木村春彦博士に心より感謝を申し上げます．私を博士課程に受け入れる以前より，木村博士には多くのご助力を賜り，入学後には以前にもまして熱心なご指導を賜りました．研究を進めるための環境や，定期的な会議における研究方針や就職に対するアドバイスなど，数えきれぬ恩義がございます．改めまして，心より感謝申し上げます．

学位論文審査において，貴重なご指導，ご支援を賜りました同大学准教授の南保英孝博士，唐堂由其博士に心より感謝を申し上げます．お二方にはゼミ内における活発な議論や，学会活動などでご支援を賜りました．

研究遂行において，貴重なご指導，ご支援を賜りました石川工業高等専門学校電子情報工学科准教授の越野亮博士に心より感謝を申し上げます．越野博士には，卒業生である私のために，昼夜問わず研究方針の相談，論文の添削など，様々なご助力を賜りました．学会活動においても，先生方のご紹介や投稿のご支援など，大変お世話になりました．

学位論文の記載において，貴重なご指導，ご支援を賜りました立命館大学情報理工学部情報システム学科助教の梶原祐輔博士に心より感謝申し上げます．梶原博士には研究室内の運用，研究の進め方，学士論文の書き方など，身近な先輩としての様々なアドバイスを賜りました．

博士課程において，同期の松田昇也博士，梅上大勝氏には，分野は違えど同学年のライバルとして，研究活動の大きな励みとなりましたことを，心より感謝申し上げます．研究歴の短い私に，初歩的な点なども優しくご教示頂きました．

研究室内において，人工知能研究室所属の皆様には，研究室生活を楽しくさせていただき，心より感謝申し上げます．特に博士１年在籍時に修士１年におられた，８名には同室にて大変お世話になりました．並びに，同研究グループとして研究活動に励んだ５名には，日々の議論など良い刺激になりました．

また，研究を進めるに辺り，ご支援，ご協力を賜りながら，ここにお名前を記すことができなかった多くの方々に心より感謝申し上げます.

最後になりますが，一度は社会人として働いていた私が，会社を辞め博士課程に進学するという決断を行った際にも，否定せず日々の生活を支えて下さった母に心から感謝申し上げますとともに，心の支えとなってくださった，妻，妹，祖母，そして天国にいる祖父に心から感謝申し上げます.

参考文献

[1] 総務省. 電気通信サービスの加入契約数等の状況, 2013.

[2] 総務省. 情報通信白書平成 24 年版, 2013.

[3] Tetsuro Hori and Kiyoharu Aizawa. Context-based video retrieval system for the life-log applications. In *Proceedings of the 5th ACM SIGMM international workshop on Multimedia information retrieval - MIR '03*, pp. 31–38, 2003.

[4] Abigail Sellen, Andrew Fogg, Mike Aitken, Steve Hodges, Carsten Rother, and Ken Wood. Do life-logging technologies support memory for the past? an experimental study using sensecam. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 81–90, 2007.

[5] A.M. Adami, T.L. Hayes, and M. Pavel. Unobtrusive monitoring of sleep patterns. In *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Vol. 2, pp. 1360–1363, 2003.

[6] 長谷川達人, 越野亮, 木村春彦. Android スマートフォンにおける近接センサによる画面ロック手法の開発. 情報処理学会論文誌, Vol. 54, No. 12, pp. 2513–2517, 2013.

[7] 長谷川達人, 越野亮, 木村春彦. State magic: Android スマートフォンの状態推定システム. マルチメディア，分散，協調とモバイル (DICOMO2015) シンポジウム, pp. 1053 – 1060, 2015.

[8] 長谷川達人, 越野亮, 葭田護, 木村春彦. 子供のスマートフォン依存を抑制する画面ロックアプリケーション. 情報処理学会論文誌教育とコンピュータ（TCE）, Vol. 1, No. 3, pp. 38–47, 2015.

[9] David D Lewis. Naive (bayes) at forty: The independence assumption in information retrieval. *Machine Learning: ECML-98*, Vol. 1398, pp. 4–15, 1998.

[10] Ion Androutsopoulos, John Koutsias, Konstantinos V. Chandrinos, George Paliouras, and Constantine D. Spyropoulos. An evaluation of naive bayesian anti-spam filtering.

In *Proceedings of the workshop on Machine Learning in the New Information Age*, pp. 9–17, 2000.

[11] Vangelis Metsis, Ion Androutsopoulos, and Georgios Paliouras. Spam filtering with naive bayes ? which naive bayes? In *Third Conference on Email and Anti-Spam (CEAS)*, 2006.

[12] Edward Cutrell, Mary Czerwinski, and Eric Horvitz. Notification, disruption, and memory: Effects of messaging interruptions on memory and performance. In *Conference on Human Computer Interaction Interact 2001*, 2001.

[13] Hélène Eyrolle and Jean-Marie Cellier. The effects of interruptions in work activity: Field and laboratory results. *Applied Ergonomics*, Vol. 31, No. 5, pp. 537–543, 2000.

[14] Arei Kobayashi, Shigeki Muramatsu, Daisuke Kamisaka, Takafumi Watanabe, Atsunori Minamikawa, Takeshi Iwamoto, and Hiroyuki Yokoyama. Shaka: User movement estimation considering reliability, power saving, and latency using mobile phone. *IEICE Transactions on Information and Systems*, Vol. E94-D, No. 6, pp. 1153–1163, 2011.

[15] Jennifer R. Kwapisz, Gary M. Weiss, and Samuel A. Moore. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*, Vol. 12, No. 2, pp. 74–82, 2010.

[16] Young Seol Lee and Sung Bae Cho. Activity recognition using hierarchical hidden markov models on a smartphone with 3d accelerometer. *Hybrid Artificial Intelligent Systems*, Vol. 6678, pp. 460–467, 2011.

[17] Kazushige Ouchi and Miwako Doi. Indoor-outdoor activity recognition by a smartphone. In *Proceedings of the 2012 ACM Conference on Ubiquitous Computing - UbiComp '12*, pp. 600–601, 2012.

[18] Zhenyu Chen, Mu Lin, Fanglin Chen, N.D. Lane, G. Cardone, Rui Wang, Tianxing Li, Yiqiang Chen, T. Choudhury, and A.T. Campbell. Unobtrusive sleep monitoring

using smartphones. In *Pervasive Computing Technologies for Healthcare (Pervasive Health), 2013 7th International Conference on*, pp. 145–152, 2013.

[19] Tian Hao, Guoliang Xing, and Gang Zhou. isleep: Unobtrusive sleep quality monitoring using smartphones. In *Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems*, pp. 4:1–4:14, 2013.

[20] K Sravani, B Koteswar Rao, and K Manohar. Automatic sound profile switching in mobile phones. *International Journal of Research in Economics & Social Sciences*, Vol. 6, p. 12 19, 2013.

[21] 長堀哲, 荒川豊, 田頭茂明, 福田晃. 複数端末の協調による自動的な設定切り換え手法に関する一検討. 情報処理学会研究報告. MBL, [モバイルコンピューティングとユビキタス通信研究会研究報告], Vol. 2011, No. 1, pp. 1–8, 2011.

[22] Ashraf Khalil and Kay Connelly. Context-aware configuration: A study on improving cell phone awareness. In *Modeling and Using Context*, Vol. 3554, pp. 197–209. 2005.

[23] Gregory D. Abowd, Anind K. Dey, Peter J. Brown, Nigel Davies, Mark Smith, and Pete Steggles. Towards a better understanding of context and context-awareness. *Computing Systems*, Vol. 40, pp. 304–307, 1999.

[24] Hans W. Gellersen, Albrecht Schmidt, and Michael Beigl. Multi-sensor context-awareness in mobile devices and smart artifacts. *Mobile Networks and Applications*, Vol. 7, No. 5, pp. 341–351, 2002.

[25] Joyce Ho and Stephen S Intille. Using context-aware computing to reduce the perceived burden of interruptions from mobile devices. *Proceedings of the SIGCHI conference on Human factors in computing systems CHI 05*, Vol. Portland,, pp. 909–918, 2005.

[26] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H. Witten. The weka data mining software: An update. *ACM SIGKDD Explorations Newsletter*, Vol. 11, No. 1, pp. 10–18, 2009.

[27] Jong Hee Kang, William Welbourne, Benjamin Stewart, and Gaetano Borriello. Extracting places from traces of locations. In *2nd ACM international workshop on Wireless mobile applications and services on WLAN hotspots*, Vol. 9, pp. 110–118, 2004.

[28] Leo Breiman. Random forests. *Machine Learning*, Vol. 45, pp. 5–32, 2001.

[29] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine Learning*, Vol. 20, pp. 273–297, 1995.

[30] Eibe Frank and Ian H Witten. Generating accurate rule sets without global optimization. In *Machine Learning: Proceedings of the Fifteenth International Conference*, pp. 144–151, 1998.

[31] 米田圭佑, 望月祐洋, 西尾信彦. 気圧センシング技術を用いた行動認識手法. 情報処理学会論文誌, Vol. 56, No. 1, pp. 260–272, 2015.

[32] Khaled Alanezi and Shivakant Mishra. Design, implementation and evaluation of a smartphone position discovery service for accurate context sensing. *Computers & Electrical Engineering*, Vol. 44, pp. 307–323, 2015.

[33] Hugo Lopez-Tovar, Andreas Charalambous, and John Dowell. Managing smartphone interruptions through adaptive modes and modulation of notifications. In *Proceedings of the 20th International Conference on Intelligent User Interfaces*, IUI '15, pp. 296–299, 2015.

[34] Seyed Amir Hoseinitabatabaei, Alexander Gluhak, and Rahim Tafazolli. Towards a position and orientation independent approach for pervasive observation of user direction with mobile phones. *Pervasive and Mobile Computing*, Vol. 17, No. A, pp. 23–42, 2015.

[35] Alireza Vahdatpour, Navid Amini, and Majid Sarrafzadeh. On-body device localization for health and medical monitoring applications. In *Pervasive Computing and Communications (PerCom), 2011 IEEE International Conference on*, pp. 37–44, 2011.

[36] Kaori Fujinami and Satoshi Kouchi. Recognizing a mobile phone's storing position as a context of a device and a user. In *In Proc. of the 9th International Conference*

on Mobile and Ubiquitous Systems: Computing, Networking and Services (MobiQuitous2012), pp. 76–88, 2012.

[37] 河内智志, 藤波香織. 携帯電話の格納場所連続監視手法～歩行時および格納動作時判定処理の文脈的併用～. 情報処理学会研究報告. UBI, [ユビキタスコンピューティングシステム], Vol. 2013, No. 19, pp. 1–8, 2013.

[38] Sungjae Hwang and Kwangyun Wohn. Vibrotactor: Low-cost placement-aware technique using vibration echoes on mobile devices. In *Proceedings of the Companion Publication of the 2013 International Conference on Intelligent User Interfaces Companion*, pp. 73–74, 2013.

[39] 内閣府. 平成 25 年度 青少年のインターネット利用環境実態調査. 入手先 http://www8.cao.go.jp/youth/youth-harm/chousa/h25/net-jittai/pdf-index.html, 2014 (accessed Sep. 27, 2014).

[40] 内閣府. 平成 21 年度 青少年のインターネット利用環境実態調査. 入手先 http://www8.cao.go.jp/youth/youth-harm/chousa/h21/net-jittai/pdf-index.html, 2014 (accessed Sep. 27, 2014).

[41] Kimberly S. Young. Internet addiction: The emergence of a new clinical disorder. *CyberPsychology & Behavior*, Vol. 1, No. 3, pp. 237–244, 1998.

[42] Motoharu Takao, Susumu Takahashi, and Masayoshi Kitamura. Addictive personality and problematic mobile phone use. *CyberPsychology & Behavior*, Vol. 12, No. 5, pp. 501–507, 2009.

[43] Bong Won Park and Kun Chang Lee. The effect of users' characteristics and experiential factors on the compulsive usage of the smartphone. *Ubiquitous Computing and Multimedia Applications*, Vol. 151, pp. 438–446, 2011.

[44] 総務省情報通信政策研究所. 高校生のスマートフォン・アプリ利用とネット依存傾向に関する調査. 入手先 http://www.soumu.go.jp/iicp/chousakenkyu/data/research/survey/telecom/2014/internet-addiction.pdf, 2014 (accessed Sep. 27, 2014).

[45] Tuncay Ayas and Mehmet Baris Horzum. Relation between depression, loneliness, self-esteem and internet addiction. *Education*, Vol. 133, No. 3, pp. 283–290, 2013.

[46] 田山淳. 高校生の携帯電話依存と心理・行動要因との関連について. 心身医学, Vol. 51, No. 3, pp. 245–253, 2011.

[47] 鶴田利郎, 山本裕子, 野嶋栄一郎. 高校生向けインターネット依存傾向測定尺度の開発. 日本教育工学会論文誌, Vol. 37, No. 4, pp. 491–504, 2014.

[48] Min Kwon, Joon-Yeop Lee, Wang Youn Won, Jae Woo Park, Jung Ah Min, Changtae Hahn, Xinyu Gu, Ji Hye Choi, and Dai-Jin Kim. Development and validation of a smartphone addiction scale (sas). *Plos One*, Vol. 8, No. 2, pp. 1–7, 2013.

[49] Choonsung Shin and Anind K. Dey. Automatically detecting problematic use of smartphones. In *Proceedings of the 2013 ACM international joint conference on Pervasive and ubiquitous computing*, pp. 335–344, 2013.

[50] Heyoung Lee, Heejune Ahn, Samwook Choi, and Wanbok Choi. The sams: Smartphone addiction management system and verification. *Journal of Medical Systems*, Vol. 38, No. 1, pp. 1–10, 2014.

[51] CNN Digital Biz. South korea pulls plug on late-night adolescent online gamers. 入手先 http://edition.cnn.com/2011/11/22/world/asia/south-korea-gaming, 2011 (accessed Sep. 27, 2014).

[52] 47NEWS. 夜 9 時から家でスマホ・携帯禁止　愛知・刈谷、全小中学校が対象. 入手先 http://www.47news.jp/CN/201403/CN2014031701001789.html, 2014 (accessed Sep. 27, 2014).

[53] 鶴田利郎. R-pdca サイクルの活動を用いたネット依存に関する授業実践 : 依存防止プログラムの成果を援用した 8 時間の授業実践の試み. 日本教育工学会論文誌, Vol. 35, No. 4, pp. 411–422, 2012.

[54] 文部科学省. 子どもの携帯電話等の利用に関する調査. 入手先 http://www.mext.go.jp/b_menu/houdou/21/05/attach/1266542.htm, 2009 (accessed Sep. 27, 2014).

.1 付録

表 1: 1 フレームから抽出する特徴ベクトル

特徴量名称	軸	対象センサ				
		加速度	重力	角速度	照度	近接
平均値	x,y,z,g	○	○	○	○	○
絶対値の平均値	x,y,z,g	○	○	○	-	-
標準偏差	x,y,z,g	○	○	○	○	○
絶対値の標準偏差	x,y,z,g	○	○	○	-	-
最小値	x,y,z,g	○	○	○	○	○
最大値	x,y,z,g	○	○	○	○	○
二乗平均平方根	x,y,z,g	○	○	○	○	○
第 1 四分位数	x,y,z,g	○	○	○	○	○
中央値	x,y,z,g	○	○	○	○	○
第 3 四分位数	x,y,z,g	○	○	○	○	○
四分位範囲	x,y,z,g	○	○	○	○	○
軸間の相関係数	x-y,y-z,z-x	○	○	○	-	-
軸間の絶対値の相関係数	x-y,y-z,z-x	○	○	○	-	-
フレーム内の初期値	x,y,z,g	-	○	-	○	○
フレーム内の最終値	x,y,z,g	-	○	-	○	○
パワースペクトルの最大値	x,y,z,g	○	-	○	-	-
パワースペクトルが最大の周波数	x,y,z,g	○	-	○	-	-
パワースペクトルの 2 番目に大きい値	x,y,z,g	○	-	○	-	-
パワースペクトルが 2 番目に大きい時の周波数	x,y,z,g	○	-	○	-	-
パワースペクトルの標準偏差	x,y,z,g	○	-	○	-	-
パワースペクトルの第 1 四分位数	x,y,z,g	○	-	○	-	-
パワースペクトルの中央値	x,y,z,g	○	-	○	-	-
パワースペクトルの第 3 四分位数	x,y,z,g	○	-	○	-	-
パワースペクトルの四分位範囲	x,y,z,g	○	-	○	-	-
パワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	-	○	-	-
低周波領域のパワースペクトルの最大値	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルが最大の周波数	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの 2 番目に大きい値	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルが 2 番目に大きい時の周波数	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの標準偏差	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの第 1 四分位数	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの中央値	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの第 3 四分位数	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの四分位範囲	x,y,z,g	○	-	○	-	-
低周波領域のパワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	-	○	-	-
中周波領域のパワースペクトルの最大値	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルが最大の周波数	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの 2 番目に大きい値	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルが 2 番目に大きい時の周波数	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの標準偏差	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの第 1 四分位数	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの中央値	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの第 3 四分位数	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの四分位範囲	x,y,z,g	○	-	○	-	-
中周波領域のパワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	-	○	-	-

高周波領域のパワースペクトルの最大値	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルが最大の周波数	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの 2 番目に大きい値	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルが 2 番目に大きい時の周波数	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの標準偏差	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの第 1 四分位数	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの中央値	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの第 3 四分位数	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの四分位範囲	x,y,z,g	○	-	○	-	-
高周波領域のパワースペクトルの各軸の相関係数	x-y,y-z,z-x	○	-	○	-	-

※軸列は加速度，重力，角速度のみを対象としている

※軸列の g は x,y,z の合力としている

※低周波領域：0-4.2Hz，中周波領域：4.2-8.4Hz，高周波領域：8.4-12.6Hz としている