

# 参加型センシングの効率化に向けた タスクレベルに対する応答時間の調査

赤池 勇磨<sup>1</sup> 荒川 豊<sup>1</sup> 諏訪 博彦<sup>1</sup> 安本 慶一<sup>1</sup>

**概要:** 参加型センシングを高効率に行うためには、センシングタスクの受信者に対して、返信しやすいタイミングでタスク依頼を行う必要がある。また、センシングタスク依頼者は、依頼したタスクに対する結果がどれくらい得られるのか知りたいという欲求がある。そこで、本研究では、9人の被験者に対して、2週間に渡って、さまざまな難易度のタスクを依頼し、その応答時間とコンテキストの関係を調査する。タスクの難易度は3種類とし、タスクの依頼手段としては、普段から利用しているLINEを用いる。実験より得られた情報を機械学習にかけて、タスクとコンテキストに対する応答時間の推定モデルを構築し、その評価と実用化に向けた課題を考察する。

## 1. はじめに

本研究で対象とする参加型センシングとは、人に何かしらのセンシングを依頼し、人が自身のスマートフォンを使って依頼された情報を取得、アップロードすることによって、低コストで広域の情報を収集可能なクラウドソーシング (Crowd Sourcing) の一つであり、近年注目を浴びている [1], [2], [3]。これまで我々は、参加型センシングを効率化する手法として、ゲーミフィケーションを用いて報酬を抑制する手法 [4] を提案しているが、実験を通して、同じ報酬であっても、その依頼タイミングによりタスクを遂行してもらえるか否かに差が出てきた。

スマートフォンに届く依頼をユーザに通知する手法は、これまでさまざまな手法が研究されており、現在のスマートフォンでは、音、バイブレーション、LEDの点滅といった端末自体で伝える方法と、画面上にポップアップで提示したり、アイコンの右上に数字で示したりするような画面上で伝える手法が主である。

これらの提示をどうすれば認知率が改善するのかという研究も進んでおり、例えば、Veljko らの InterruptMe [5] では、スマートフォンを用いてユーザのコンテキストを把握し、そのコンテキストに応じた割り込みタイミングで情報を通知する手法が提案されている。同様に、Okoshi らの Attelia [6] もスマートフォンを用いて、スマートフォンの使用状況を分析し、作業が中断している時に通知すること

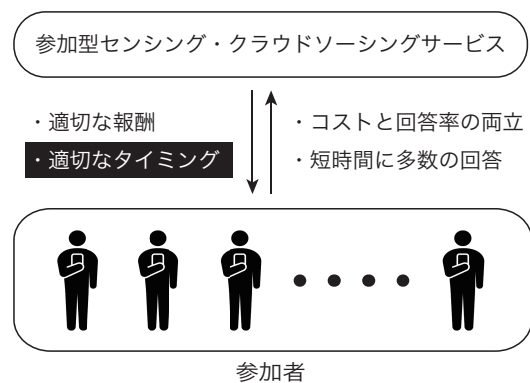


図 1 本研究の狙い

で通知に対する認知率を向上させることに成功している。ただし、これらは通知を受け取ったスマートフォンがそれを提示するか否かやその提示手法を変化させる (例えば、歩行中に届いた情報はすぐに通知せずに、ユーザが信号で立ち止まったときにまとめて通知するなど) というように、受信者側で判断する手法である。また、通知に対して気づくか否かについてのみに考えられており、参加型センシングのように通知に気づいた後、何らかの返信を要するものに対して返信したか否かは評価されていない。

スマートフォンからの通知は、スマートフォンから人間に対する割り込みと見なすことができ、頻繁な割り込みはそのユーザの集中力の低下やストレスを引き起こすといった問題が指摘されている [7], [8]。参加型センシングについて言えば、不適切なタイミングにセンシング依頼が頻繁に届くと、そのユーザがセンシング自体に参加しなくなる可能性もある。

<sup>1</sup> 奈良先端科学技術大学院大学  
Nara Institute of Science and Technology  
〒630-0192, 奈良県生駒市高山町 8916-5

このような背景のもと、本研究では、図1に示すように、参加型センシングにおいてセンシングタスクを依頼する際に、受信者と依頼内容に基づいて、あるタイミングにおける受信者の依頼遂行確率、あるいは、依頼遂行確率の高い送信タイミングを推定することを目標とする。対象とするタスク受信者が何分以内に返信（タスク遂行）を行える可能性が高いかが分かれば、参加型センシングの依頼者はどの程度の情報が集まるかを推測することができる。また返信できる可能性が低い受信者群には依頼を送らないことも可能となることから、遂行できないタイミングに多くの依頼を受信し、参加モチベーションが低下するといった参加型センシングにおける問題点を軽減できると考えている。

本論文では、その第一歩として、受信者のコンテキストに応じた通知タイミングの推定モデルを構築するための実験を行い、得られたデータからタスクへの応答時間と受信者の忙しさの推定モデルを構築した結果を報告する。実験では、9人の対象者に2週間1日3回程度のタスクを依頼し、その応答時間を計測した。この実験は、心理的なバイアスをかけないように、覆面調査で行い、対象者に対してそれが実験であることを伝えていない。そして、タスクの依頼手段として、実験実施者と対象者が普段コミュニケーションを取るために利用しているLINE<sup>\*2</sup>を用いている。また、実験実施者と対象は、同級生であり、上司や先生からの心理的プレッシャーの影響を可能な限り排除している。LINEを通じて、返信が必要なメッセージ（例えば、「修士論文何ページ書いた？」など）を参加型センシングのタスクとみなし、その質問に対する返答がセンシング結果であると見なす。難易度の異なる複数の質問を用意し、朝、昼、夜の3回にそれぞれ異なる質問を対象者に送付する。そして、2週間の計測終了後に、対象者を集めて、実験であった旨を説明し、各回のやり取り時の状況をアンケートにより収集する。対象者が記憶をたぐりやすいように、実験に先立ち、別の実験を装ってMoves<sup>\*3</sup>というライフログアプリを各自のスマートフォンにインストールを指示していた。

最終的に、本実験では、計259件のデータセット（受信者（被験者）、受信時刻、応答時刻、メッセージの内容レベル、受信時の受信者の行動、受信時の受信者の位置、受信時の受信者が移動していたか否か、受信時の受信者の暇度）の収集に成功した。そして、これらのデータから応答時間とコンテキストの関係性を分析した結果、通知メッセージに対する応答の速さは、受信した時間帯やメッセージ内容のレベル、その際の受信者の暇度（忙しさを定義するために設けた指標）に関係している傾向が確認できた。これらのデータはプライバシー問題の点を考慮しても比較的取得し易いデータであり、どういったコンテキスト時に応答時間が早いかを推測する為のデータとして有用性、実用性が

高いと考えられる。

次に、これらのデータを用いて、機械学習によってユーザコンテキストに対する応答時間推定モデルと忙しさ推定モデルを構築した。分類器にはSVM, RandomForest, J48を用いて分析を行った[9]。結果として、最大46.3%のF値で「5分以内」、「1時間以内」、「1時間以上」の3段階に分割した割り込み通知への応答時間を推定することができた。また、応答時間ではなく、受信者の忙しさに関しても同様に推定した場合、こちらは最大71.8%の精度にて推定が可能であることを確認した。応答時間に関しては実用面で理想的な精度を得ることができなかった。しかし、忙しさの推定が実用的な値であるものとし、忙しさを入力値として応答時間推定モデルに組み込んだ結果、最大53.3%の精度で応答時間を推定することが可能であることが確認できた。ランダムに応答時間の推定を行った場合、約3割の割合で5分以内にメッセージの返信があったため、この推定モデルを用いることで、20%以上高い割合で応答時間を予測することが可能であることを示した。

## 2. 関連研究

ユーザへの通知割り込みに関する研究として、Veljkoらは、メッセージを受信した際のユーザのコンテキストと、その際の感情（Happy, Sad, Bored等）に関するデータを収集し、メッセージの受信タイミングに対する満足度を推定するモデルを提案した[5]。このようにスマートフォンをセンシングデバイスとして用いたこれらの先行研究では、モバイル端末における幅広いユーザコンテキストについてのデータを暗黙的に取得し用いることができる。また、OkoshiらのAttelia[6]では、スマートフォンを用いて、ユーザの動作を認識し、作業が中断している時に通知することで通知に対する認知率を向上させることに成功している。

しかし、研究成果を一般のユーザへの適用を考えた際、受信者のコンテキストだけでなく、メッセージの内容や緊急性といった送信者の需要も考慮するべきであると考えられる。また、受信者側においても、受信したメッセージの長さやそこに書かれたタスクの重さは、応答時間へ影響を及ぼすと考えられることから、メッセージの内容について着目することは重要であると言える。

割り込みタイミングの推定というテーマとは異なるが、Hammerらは、プッシュ通知への応答時間や、その他のスマートフォンから取得できるデータを用いて、ユーザの忙しさに関するコンテキストを推定できることを示している[10]。この研究から、応答時間や忙しさと行った割り込みへの許容度具合に大きく関係すると思われる要素は、スマートフォンセンサーから得られるデータから推測することが可能であると考えられる。

\*2 <http://line.me/>

\*3 <https://www.moves-app.com/>

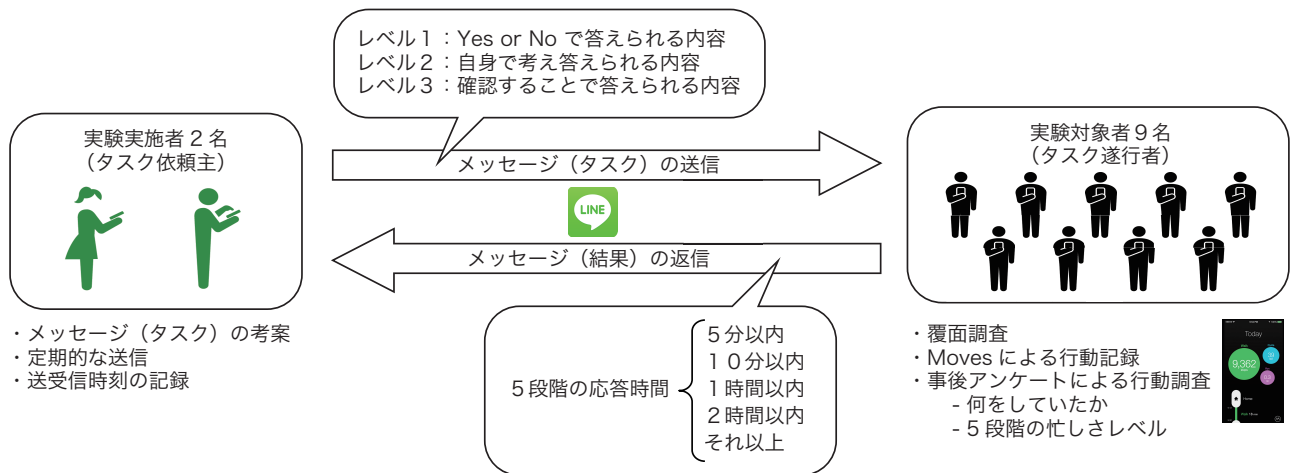


図 2 本実験の全体構成

### 3. 調査実験について

本研究では、スマートフォンにて取得できる受信者のコンテキストデータから応答時間と忙しさを求めることに着目するため、受信者のコンテキストデータと、その際の応答時間や受信者の忙しさに関するデータを収集し、両者がどのような関係性を持つかについて考察する。その後、同じデータを用いて、応答時間と受信者の忙しさを推定するモデルを機械学習により構築する。

図 2 に本実験の全体構成を示す。タスク遂行者に当たる実験対象者はすべて大学院生の 9 名であり、年齢は 23~24 歳、性別は男 7 名、女 2 名である。タスク依頼者に相当する実験実施者は男女 1 名ずつ計 2 名の大学院生であり、年齢は 24~25 歳であり、2 週間に渡り、実験対象者に対して、タスクとなるメッセージを送り、そのタスクに対する応答時間を記録する。通知には代表的なインスタントメッセージャーサービスであり、1 日あたりのユーザから得ることができるメッセージ量が顕著に多く、取得できる時間帯が広いという特徴を持つ“LINE”を使用する。また、実験条件は予め被験者には伝えず、実験期間を終えた後に実験説明を行い、それまでに取得したログを本研究に使用する承諾を得るという方法を用いる。

#### 3.1 タスクの内容と依頼時刻

通知されるタスクの内容は、難易度を考慮し 3 つのレベルに分類し設定した。具体的なメッセージ内容を表 1 に示す。また、通知されるタスクのレベルは、被験者による個人差を考慮し各被験者に均等な量が割り当てられた。また順序効果を考慮し、各被験者に対し同じレベルのタスクが連続して送信されないようにした上で、朝 (午前 9:00~午前 11:59)、昼 (午後 12:00~午後 14:59)、夕 (午前 15:00~午後 17:59) の各時間帯に、被験者毎に 1 日 1 回ずつ行った。

表 1 レベル毎の送信メッセージの具体例

| 難易度   | メッセージ内容の定義                  | 具体例  |
|-------|-----------------------------|--|
| レベル 1 | 被験者が Yes or No で答えられるであろう内容 | 明日学校に来ますか?<br>外は晴れていますか?<br>もうご飯は食べましたか?           |
| レベル 2 | 被験者が自身の考えで答えられるであろう内容       | 具合はいかがですか?<br>今何をしていますか?<br>正月は何日に帰省しますか?          |
| レベル 3 | 被験者が確認することで答えられるであろう内容      | 〇〇さんは研究室に居ますか?<br>〇〇日の予定は空いていますか?<br>修論の提出日はいつですか? |

#### 3.2 コンテキスト情報の取得

本実験では、タスクを受信した際に、受信者がどのような状態であったかというコンテキスト情報が必要である。調査を覆面で行うため、2つの手法を用いてコンテキスト情報を取得している。ひとつは、スマートフォンアプリケーションである Moves、もうひとつは事後のアンケート調査である。

前者は、iPhone と Android の両プラットフォームに対して対応したライフログアプリであり、ユーザの位置情報、移動手段、移動時間、歩数、といった情報をバックグラウンドで自動的に収集し、可視化してくれる無料のアプリケーションである。このアプリケーションで収集されたデータはクラウド上にアップされ、API (Application Programming Interface) を通じて、実験実施者が確認することもできることから、このアプリケーションを用いて、被験者が通知の受信時に

- 移動中であったか否か
- どの場所に居たか
- どういった手段で移動していたか

にという情報を収集した。本アプリケーションの導入にあたっては、別の実験を装い、事前に対象者候補に Moves をインストールしてもらい、日頃アプリケーションを起動させログの記録を行うことを薦めておき、候補群の中で実際に期間中 Moves アプリケーションを利用していたユーザ

表 2 得られた結果の例

| 依頼内容               | レベル | 受信時のコンテキスト |       |     |       | 返信時のコンテキスト |        |     |       |
|--------------------|-----|------------|-------|-----|-------|------------|--------|-----|-------|
|                    |     | 状態         | 場所    | 同行者 | Moves | 状態         | 場所     | 同行者 | Moves |
| 今日学校来る？            | 1   | 睡眠         | 自宅    | 1人  | 停滞中   | 睡眠         | 自宅     | 1人  | 停滞中   |
| ところで、いま実家？         | 1   | 岩盤浴        | 銭湯    | 友人  | 停滞中   | 岩盤浴        | 銭湯     | 友人  | 停滞中   |
| 食べれる奴？             | 1   | 入浴         | 銭湯    | 1人  | 停滞中   | 着替え中       | 銭湯     | 1人  | 停滞中   |
| 学校なうスカ？            | 1   | 輪講準備       | 奈良先端大 | 1人  | 停滞中   | 輪講準備       | 家      | 1人  | 停滞中   |
| ところで、いま実家？         | 1   | ボード        | ハチ北   | 友達  | 移動中   | ボード        | 家      | 友達  | 移動中   |
| 年始帰るん？             | 1   | 研究         | 研究室   | 単独  | 停滞中   | 研究         | 研究室    | 単独  | 停滞中   |
| 被験者への承諾書について       | 2   | 深い睡眠中      | 自宅    | 単独  | 停滞中   | 起きた直後      | 自宅     | 単独  | 停滞中   |
| カラオケ何時間ぐらいおりたい？    | 2   | 初詣         | 伊勢神宮  | 両親  | 移動中   | 初詣         | 伊勢神宮   | 両親  | 移動中   |
| いつ帰省するの？           | 2   | 論文執筆       | 家     | 一人  | 停滞中   | 論文執筆       | 家      | 一人  | 停滞中   |
| 4日カラオケ何時ならいける？     | 3   | 睡眠         | 自宅    | 個人  | 停滞中   | 朝食         | 自宅     | 個人  | 停滞中   |
| 修論って何ページとか決まってるん？  | 3   | 睡眠         | 自宅    | 個人  | 停滞中   | 移動         | 学研北生駒駅 | 個人  | 移動中   |
| 昨日ムーブス何回ぐらい場所変わった？ | 3   | 睡眠         | 家     | 一人  | 停滞中   | テレビ        | 家      | 一人  | 停滞中   |

を本実験での被験者として抜粋している。

後者については、実験終了後、ここ最近の質問が実験の一環であったこと説明した上で、被験者に対してアンケート調査を行い、Moves に記録された情報を見ながら記憶を思い出してもらい

- 忙しさ

について5段階(とても忙しい・忙しい・どちらでもない・暇・とても暇)で回答してもらった。

#### 4. 実験結果

2週間に渡る調査の結果、本実験では、計259件のデータ収集に成功した。表2に得られた結果の一例を示す。データには、受信者(被験者)、受信時刻、応答時刻、メッセージの内容レベル、受信時の受信者のコンテキスト(状態・場所・同行者・Movesの結果)、返信時の受信者のコンテキスト(状態・場所・同行者・Movesの結果)が含まれている。

以降では、収集したデータのうち、欠損値を含む不完全なデータを除いた199件のデータを用いて分析する。199件に含まれるデータの内訳は、図3および図4に示す。本実験では、1日の4つの時間帯にメッセージを送っており、図3(左)に示すようにその割合は概ね均等である。一方、被験者が学生であることから、図3(右)のように、受信時は1人であることが多かった。

次に、メッセージ受信時の状態(コンテキスト)として




図 3 メッセージの受信時刻(左)と受信時の同行者の割合(右)




図 4 メッセージ受信時のコンテキストの割合

は、図4に示すように、学業(研究室あるいは講義中)が最も多く、次に睡眠、屋内活動(大学以外の施設)という順であった。

#### 4.1 コンテキストデータと応答時間の関係性の分析

収集したデータを用いて、応答時間や受信者の忙しさの推定モデルを構築する上で、まず受信者のコンテキストや、受信するメッセージの特徴、応答時間の間に関係性が存在するか否かを調べる必要がある。そこで初めに、収集したデータの中で、連続値として存在する各属性

- メッセージの受信時間
- メッセージの内容のレベル
- メッセージ受信時の被験者の忙しさ

と応答時間の関係性を調査する。その際、メッセージの受信時間、メッセージの内容のレベル、は送信されるメッセージの特徴、メッセージ受信時の被験者の忙しさ、は受信者の状態を示している。

#### 4.1.1 メッセージの受信時間と応答時間の関係

通知された各タスクの受信時刻と応答時間の関係を図5に示す。各時間帯での応答時間は、朝の応答時間(平均1時間48分、最大10時間、最小1分以内)、昼の応答時間(平均51分、最大6時間24分、最小1分以内)、夜の応答






図 5 応答時間とタスク受信時間帯の関係




図 7 同行者とタスクレベルと応答時間の関係




図 6 応答時間に対する取得データ数の分布




図 8 受信時間帯と応答時間の関係

時間（平均 37 分，最大 4 時間 18 分，最小 1 分以内）と、平均値も最悪値も朝，昼，夕方の方で小さくなることわかった。この傾向は，一般的に活動を活発に行う日中の時間帯よりも，1 日のタスクを終え始める遅い時間帯の方が，与えられたタスクに対応しやすいからであると考えられる。この結果より，前項と同様，通知する時間帯は応答時間と関係性を持っており，応答時間の推定に利用することができると言える。

#### 4.1.2 タスクレベルと応答時間の関係

送信された各タスクのレベルと，被験者が応答するまでの時間の関係を図 6 に示す。5 分以内に応答が得られることが最も多く，次に 2 時間以上あけて応答が得られることが多かった。各レベルに対する平均応答時間は，58 分（レベル 1），1 時間 15 分（レベル 2），1 時間 13 分（レベル 3）と，レベル 1，3，2 の順で応答時間は早かった。その結果，応答時間とタスクレベルには関係性が存在すると考えられ，タスクのレベルに関するデータは応答時間の推定に有効である可能性を確認した。また，分析前はタスクのレベルが低い順に受信者にとっての返事の敷居が低く，応答時間が短いものと思われたが，結果は，小さな差ではあるがレベル 3 のほうがレベル 2 よりも応答に時間が必要であることを示した。これは，調べることで答えることがで

きるというタスクと，自分で回答を考える必要があるタスクの難易度を比べた場合，前者の方が難易度の高いタスクであったと考えられる。よって，タスクの難易度を設定する際は，受信者が回答をどのように作る必要があるかが大きく関係していると言え，割り込むタスクの難易度を設定する上で重要になると考える。

#### 4.2 同行者とタスクレベルと応答時間の関係

図 7 に，同行者およびタスクレベル別の平均応答時間とその分散を示す。最も平均応答時間が長くなるのは「家族」というときにレベル 1 のタスクを受信したときである。レベル 1 のメッセージは Yes/No で回答可能な質問であるため，家族という場合は返信よりも家族を優先すると考えられる。レベル 3 のタスクに着目すると，同僚と居るとき（＝本実験では被験者が学生であるため，研究室にいると同意）は平均応答時間が最も短く，その分散も小さい。大学にいるときは，パソコンで作業していることが多いため，レベル 3 の質問に対しても即座に調べて回答できたと考えられる。一方，誰かといると総じて回答が遅くなり，1 人でいる場合も後回しにしてしまうと考えられる。




図9 応答時間と忙しさの関係

### 4.3 受信時間帯と応答時間の関係

図8にタスクの受信時間に対するレベル別の平均応答時間とその分散を示す。この図から、朝と夜はどのようなレベルでも応答に要する時間が長くなることと言える。この理由としては、被験者である学生にとって、朝9時台は、通学、講義、または寝ているという可能性が考えられる。夜は、食事中であることが多く、返信が食後、研究室に戻ってからとなるためではないかと考えられる。

#### 4.3.1 忙しさと応答時間の関係

各メッセージが送信された際の被験者の忙しさと応答時間の関係を図9に示す。結果として、2(忙しい)と4(暇)と答えられた際のメッセージへの応答が顕著に早く、反対に5(とても忙しい)、3(どちらでもない)と答えられた際の応答時間が顕著に遅かった。実験を行う前の仮説では、受信者の忙しさに伴い通知メッセージへの返信は困難になると考えていたが、実際は同じ2(忙しい)に相当する1(とても忙しい)と2(忙しい)の間に大きい差が生まれた。

この結果を考察するにあたり、実験後被験者に対し、「なぜ忙しさのレベルが1の時は返信できず、忙しさのレベルが2の時は返信できたケースが多かったのか」について尋ねたところ、どうしても外せない作業中でない限り、少し忙しい時の方が返しやすくと答えた被験者が多く存在した。割り込みメッセージへの返信をタスクと捉えた場合、作業中のタスクのついでに片付けてしまうというケースが意外にも多く存在することが示された。そして、受信者の忙しさのレベルを、レベル1(とても忙しい)とレベル2(忙しい)のどちらであるか、もしくはレベル4(暇)とレベル5(とても暇)のどちらであるかで応答時間に大きく差を生む傾向が確認できた。

これらの結果から、タスクレベル1で夕方に送られるタスクへの返信が一番早いと推測されるが、より正確な推測を行うためには応答時間と複数の要素を複合的に観察する必要があると考えられる。

## 5. 機械学習による割り込みに対する許容度合いの推定

収集した受信者のコンテキストデータや、その際のメッセージへの応答時間や忙しさのデータを用いて、実際に応答時間と受信者の忙しさの推定モデルを構築し、それらがどの程度の精度で行えるかを検証する。本研究では機械学習により得られるF値を推定モデルの精度として扱う。被験者から得られたデータより、以下の6種の属性値と、正解値として通知に対する応答時間のデータを入力値として、機械学習を用いて応答時間を推定する。

- 送信者(実験者)が誰か
- 送信メッセージの内容のレベル(3種類)
- 送信者(実験者)のメッセージ送信時間帯(4種類)
- 受信者(被験者)の行動カテゴリ(18種類)
- 受信者(被験者)の場所カテゴリ(8種類)
- 受信者(被験者)の“Moves”ログの種類(2種類)

機械学習には、全データセット259件の中から、1つ以上欠損値を含むものを除外した計199件のデータセットを用い、機械学習アルゴリズムにはSVM、RandomForest、J48を用いる。

### 5.1 応答時間の推定結果

本章で行った全ての機械学習の結果を表3に示す。応答時間に関しては、5段階の推定は最大で37.0%、3段階(5分以内、1時間以内、それ以上)では最大46.3%、2段階では最大64.8%の精度で推定可能であることが確認できた。また、受信時の忙しさに関しては、最大71.8%の精度で推定することができた。

ここで、受信時の忙しさ推定が実用的なレベルの精度で推定できることに着目し、受信者の忙しさも受信者のコンテキストデータとして用いることができるものとし、「応答時間」の推定を改めて行った。その結果、受信時の忙しさを情報の1つとして用いることで、最大53.3%の精度で3段階の受信者の忙しさを推定することができた。これは受信者の忙しさを入力値として用いなかった場合の推定モデルと比べて、最大約13%高い精度である。しかしながら、実用性を考慮した場合、得られた応答時間の推定精度は理想的な値であるとは言えない。しかし、ランダムなタイミングで実際に通知を行った場合、5分以内に応答があったサンプル数が全体の35.5%であったことから、提案モデルを用いることでランダムな場合よりも20%高い精度で、5分以内に応答が返ってくるタイミングを推定することができると言える。

## 6. おわりに

本論文では、被験者に対して実際のタスク通知を行い、

表 3 各分類器による機械学習の結果

|               |           | 応答時間<br>(5 段階) | 応答時間<br>(3 段階) | 応答時間<br>(2 段階) | 忙しさ<br>(5 段階) | 忙しさをういた<br>応答時間 (3 段階) |
|---------------|-----------|----------------|----------------|----------------|---------------|------------------------|
| J48           | precision | 35.7%          | 47.3%          | 41.6%          | 63.8%         | 50.7%                  |
|               | recall    | 41.3%          | 47.1%          | 64.5%          | 65.1%         | 50.5%                  |
|               | F-measure | 37.4%          | 46.3%          | 50.6%          | 63.3%         | 50.0%                  |
| SVM           | precision | 31.9%          | 32.1%          | 41.6%          | 65.7%         | 53.9%                  |
|               | recall    | 43.6%          | 43.6 %         | 64.5%          | 54.1%         | 53.4%                  |
|               | F-measure | 36.9%          | 36.9 %         | 50.6%          | 42.2%         | 53.3%                  |
| Random forest | precision | 36.2%          | 43.0 %         | 64.5%          | 71.4%         | 48.9%                  |
|               | recall    | 38.4%          | 43.0%          | 65.7%          | 72.7%         | 49.0%                  |
|               | F-measure | 37.0%          | 43.0%          | 64.8%          | 71.8%         | 49.0%                  |
| 実測値           |           | 35.5%          | 35.5%          | 35.5%          | 22.1%         | 35.5%                  |

通知に対する応答時間とその際のユーザコンテキストデータを収集した。収集したデータセットを用いて、応答時間とユーザコンテキストに関するデータにどのような関係性が存在するかを分析し、その後、同データセットを用いて機械学習による応答時間とユーザの忙しさを推定するモデルを構築した。

分析の結果、通知に対する応答時間はメッセージ内容のレベル、送信時間帯、受信時の忙しさと関係性を持つことが確認できた。具体的には、「レベル1のメッセージを送るなら相手が暇な時」、「夕方メッセージを送るなら相手が忙しい時」等の傾向が見られた。この結果から、収集したコンテキストデータには応答時間を求める上での相関関係が存在すると考えられ、適切な割り込みタイミングの推定モデルの入力値として有効に用いられる可能性を示した。

次に、実際に得られた199件のデータセット（「タスクの内容レベル」、「受信者」、「送信時刻（受信時刻）」、「ユーザの行動」、「ユーザの現在位置」、「ユーザが移動中か否か」の6種類のデータのセット）を3種類の機械学習アルゴリズムを用いて分析し、どの程度の精度で応答時間の推定とユーザの忙しさを推定が可能であるかを検証した。その結果、忙しさを推定については、「とても忙しい」「忙しい」「どちらでもない」「暇」「とても暇」の5段階のどれに相当するかを推定する場合、70%以上の精度で推定可能であることを示した。応答時間の推定については、忙しさのコンテキストデータも入力値として使用することで、通知するメッセージの応答時間が「5分以内」、「1時間以内」、「1時間以上」のどれにあたるかを推定する場合、ランダムに応答時間を推定する場合と比べ、20%高い51%の精度で応答時間を推定することができた。

## 6.1 今後の展望

構築した応答時間の推定モデルでは、53.3%という精度で3段階の応答時間を推定できている。しかしこの精度は実用面で見えた場合、更なる向上が求められる。そのためには、より受信者のコンテキストと関係性の強いデータをセ

ンシングする必要があると考える。具体的には、本研究では着目していなかったユーザの精神面（その日の気分や体調、送信者に対する機嫌等）のデータが効果的であると考えられる。

推定モデルの実用化の面では、実験で用いたそれぞれのデータセットは個人差（例えば朝に早くメッセージを返す傾向のあるユーザもいれば遅く返す傾向を持つユーザも存在する。）が大きく存在することも確認され、他人のデータを用いた学習では十分な推定が行えない可能性が高い。その場合、新しいユーザは、一定のデータ量が蓄積されるまで推定モデルを利用できないというコールドスタート問題が課題としてあげられる。この課題に関しても同様に、応答時間やユーザの忙しさと関係性を持つ新たなデータを加えることで解決が見込めると考える。

本研究では1日あたりの投稿量や代表的なアプリケーションであることを考慮し、通知を行うプラットフォームとしてLINEにのみ着目し、独自に作成したプログラムを用いてこれらのログを取得した。しかし、職場等業務的なタスク内容に関する割り込みを行うシチュエーションで例えば、長文のやりとりやファイルの添付が可能であるGmail等のプラットフォームにも着目する必要があると考える。よって推定モデルの実用化を考えた場合、他の通知プラットフォームにおいても同様の実験を行う必要がある。

**謝辞** 本研究は総務省戦略的情報通信研究開発推進事業(SCOPE)の支援を受けて実施している。

## 参考文献

- [1] Burke, J. A., Estrin, D., Hansen, M., Parker, A., Ramanathan, N., Reddy, S. and Srivastava, M. B.: Participatory sensing, *Center for Embedded Network Sensing* (2006).
- [2] Lane, N. D., Eisenman, S. B., Musolesi, M., Miluzzo, E. and Campbell, A. T.: Urban sensing systems: opportunistic or participatory?, *Proceedings of the 9th workshop on Mobile computing systems and applications*, ACM, pp. 11-16 (2008).

- [3] Dutta, P., Aoki, P. M., Kumar, N., Mainwaring, A., Myers, C., Willett, W. and Woodruff, A.: Common sense: participatory urban sensing using a network of handheld air quality monitors, *Proceedings of the 7th ACM conference on embedded networked sensor systems*, ACM, pp. 349–350 (2009).
- [4] Ueyama, Y., Tamai, M., Arakawa, Y. and Yasumoto, K.: Gamification-based incentive mechanism for participatory sensing, *Pervasive Computing and Communications Workshops (PERCOM Workshops), 2014 IEEE International Conference on*, IEEE, pp. 98–103 (2014).
- [5] Pejovic, V. and Musolesi, M.: InterruptMe: designing intelligent prompting mechanisms for pervasive applications, *Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, ACM, pp. 897–908 (2014).
- [6] T. Okoshi, J. Ramos, H. N. J. N. A. D. and Tokuda, H.: Attelia: Reducing User’s Cognitive Load due to Interruptive Notifications on Smart Phones, *Proceedings of IEEE International Conference on Pervasive Computing and Communications 2015 (PerCom ’15)*, ACM, pp. 96–104 (2015).
- [7] Perlow, L. A.: *Administrative science quarterly*, Vol. 44, No. 1, pp. 57–81 (1999).
- [8] Cutrell, E., Czerwinski, M. and Horvitz, E.: Notification, disruption, and memory: Effects of messaging interruptions on memory and performance (2001).
- [9] Berry, M. J. and Linoff, G.: *Data mining techniques: for marketing, sales, and customer support*, John Wiley & Sons, Inc. (1997).
- [10] Hammer, J. C. and Yan, T.: Exploiting usage statistics for energy-efficient logical status inference on mobile phones, *Proceedings of the 2014 ACM International Symposium on Wearable Computers*, ACM, pp. 35–42 (2014).