

参加型センシングの効率化に向けた コンテキストに基づく応答の推定

赤池 勇磨¹ 荒川 豊¹ 諏訪 博彦^{1,a)} 安本 慶一¹

受付日 2015年6月1日, 採録日 2015年11月5日

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すぐに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週間にわたって, 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した. 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を用いた. 実験により, 応答時間には, 応答時間帯と受信者の忙しさが影響を及ぼすことが明らかになった. また, 3つのシナリオに基づいて, 応答の推定モデルを構築した結果, スマートフォンなどから得られる受信者の状態情報を属性値として用いることで, より高効率に参加型センシングの依頼が行える可能性を示した.

キーワード: 参加型センシング, 割込み, 応答時間, コンテキスト, 機械学習

Estimation of the Response Based on the Context Sensing

YUMA AKAIKE¹ YUTAKA ARAKAWA¹ HIROHIKO SUWA^{1,a)} KEIICHI YASUMOTO¹

Received: June 1, 2015, Accepted: November 5, 2015

Abstract: For efficient participatory sensing, it is necessary to request the task at the good timing to the user. The client has a desire that they want to know the results from the users as soon as possible. Thus, we have researched the relation between response time and the user's context based on experiment for two weeks to nine subjects. In the experiment, the task level was set up three levels, and the request method of the tasks was used "LINE" that generally has been using by each subjects. As a result, we clarify that the response time is influenced by time zone and the user's busyness. Additionally, as a result of estimation of the response time based on three scenarios, we demonstrate that it can be more efficiently to ask the task of participatory sensing by using the context information of the recipient from smart phones as an attribute value.

Keywords: participatory sensing, interrupt, response time, context, machine learning

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1つであり, 近年注目を浴び

ている [1], [2], [3]. 参加型センシングを用いた具体的なセンシング例としては, 騒音 (マイク) [3] や街灯の明るさ (明るさセンサ) [4], 場の状況 (カメラ) [5] などがあげられる. 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 [5], [6] 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るようになってきた.

それでは, どのようなタイミングで依頼すると, ユーザのタスク遂行率は上がるのであろうか. スマートフォンに

¹ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology, Ikoma, Nara 630-0192, Japan

^{a)} h-suwa@is.naist.jp




図 1 本研究の狙い

Fig. 1 The aim of our research.

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されるのかという研究も進んでいる[7], [8]。しかし、これらは通知を受け取った受信者側で判断する手法であり、参加型センシングの依頼者側での制御を考えていない。また、通知に対して気づくか否かについてののみ考えられており、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込みと見なすことができ、頻繁な割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[9], [10]。参加型センシングについていえば、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。

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1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とるために利用しているLINE^{*1}を用いている。また、実験実施者と対象は、学生同士とし、上司や先生からの心理的プレッシャ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（たとえば、「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見なし、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、各回のやりと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^{*2}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198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早さは、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やすいデータであり、こ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ため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推定モデルを構築した。得られるユーザコンテキストの種別から3つのシナリオを想定し、将来、どのようなコンテキストをセンシングすることで、より効率的な参加型センシングタスクの依頼が可能になるか検討した。モデル構築には代表的な機械学習アルゴリズムの1つであるRandomForestを用いた[11]。結果として、精緻にユーザコンテキストが把握できている状態を想定してモデルを構築した場合、58.6%という適合率で5分以内に応答してくれるユーザを推定できることを確認した。推定モデルを用いないでタスクを依頼した場合の5分以内の応答率は33.3%であることから、推定モデルを用いることで応答率を25%以上向上させており、より高効率に参加型センシングの依頼が行える可能性を示したと考える。

*1 <http://line.me/>*2 <https://www.moves-app.com/>

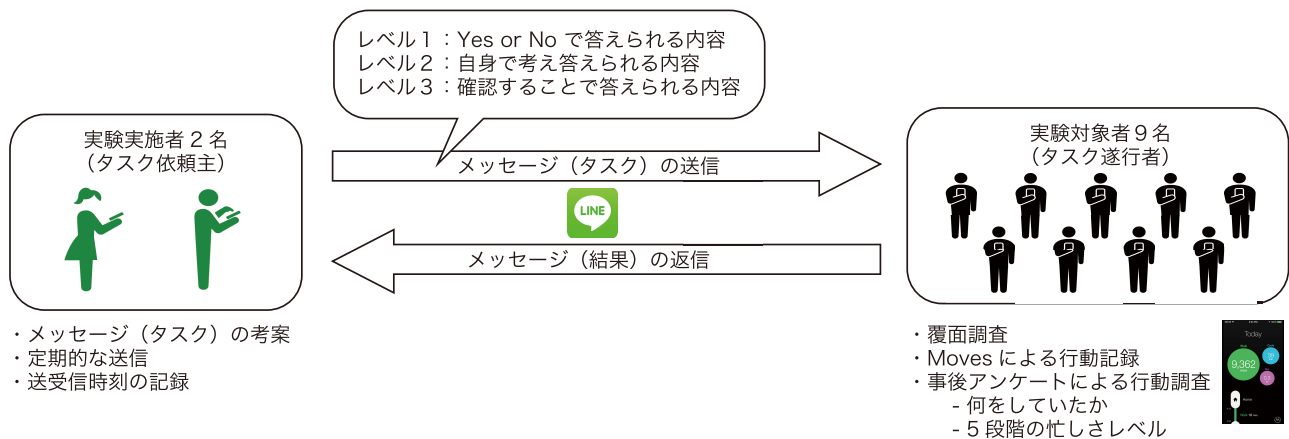


図 2 本実験の全体構成

Fig. 2 Framework of our experiment.

なお、著者らは参加型センシングの効率化を検討するために、タスクの応答時間に着目した研究発表も行っている [12]. 本論文は、この既存研究の知見に加え、依頼者にとってより重要と考える「応答の推定：タスク受信者が応答するかどうか」に着目し、収集したデータを分析しなおしたものである。

2. 関連研究

ユーザへの通知割込みに関する研究として、Pejovic 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 など) 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 [7]. 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 [8] 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とき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いえる。

割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 [13]. この研究から、応答時間や忙しさで行った割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。本研究ではこれらの点を考慮し、一般のユーザへの適用を第 1 に考え、送信者が得られる範囲での受信者のコンテキストデータを使い、メッセージ通知における適切な割込みを行ううえでヒントとして応答時間の推定を行い、またそれがどの程度の精度で実現できるかを検証する。

3. 調査実験概要

本調査実験では、スマートフォンで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。タスク遂行者にあたる実験対象者はすべて大学院生の 9 人であり、年齢は 23~24 歳、性別は男 7 人、女 2 人である。タスク依頼者に相当する実験実施者は男女 1 人ずつ計 2 人の大学院生であり、年齢は 24~25 歳であり、2 週間にわたり、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、実験バイアスを避けるために、実験内容についてあらかじ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。タスクレベルが恣意的にならないように、まず各レ

表 1 レベルごとの送信メッセージの具体例
Table 1 Example of message with each level.

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？ 外は晴れていますか？ 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？ 今何をしていますか？ 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いますか？ 〇〇日の予定は空いていますか？ 修論の提出日はいつですか？

ベルのメッセージ内容を定義し、その定義に基づいて具体的な送信メッセージを検討している。レベル 1 は、被験者にとって Yes/No で簡単に返信できると思われる内容であり、具体的には食事や通学に関する会話である。レベル 2 は、少し考えて短めの文章で回答と思われる内容であり、具体的には、何をしています？といった曖昧な質問となる。レベル 3 は、過去のメールやカレンダーなど別のアプリケーションなどで確認してから返信と思われる内容であり、具体的にはある時間の予定を質問するという内容となる。なお、実際の LINE 上では、会話が不自然にならないように、表内に示した具体例を普段の口調や内容に合うようにアレンジして送信している。

また、どのタスクレベルのメッセージをどの時間帯に送信するかは事前に計画を立て、その計画に従って送信している。通知されるタスクのレベルは、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うえで、朝（午前 8:00～午前 11:59）、昼（午後 12:00～午後 15:59）、夕（午前 16:00～午後 19:59）の各時間帯に、被験者ごとに 1 日 1 回ずつ行った。

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。1つは、スマートフォンアプリケーションである Moves、もう1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
- どの場所にいたか
- どういった手段で移動していたか

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を本実験での被験者として依頼している。

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を説明したうえで、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：どれくらい忙しかったか（とても忙しい・忙しい・どちらでもない・暇・とても暇）
- コンテキスト：何をしていたか（屋内活動、屋外活動、食事、学業、睡眠など）
- 同行者：誰といたか（1 人、家族、同僚、友人）

について、回答を依頼している。

4. 実験結果

2 週間にわたる調査の結果、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）などが含まれている。

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 198 件のデータを用いて分析する。198 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 3 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おおむね均等である。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。また、図 5 に応答時間の頻度分布を示す。5 分以内の応答が多く（66 件、33.3%）、時間が長くなるにつれて減少している。

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うえで、まず受信時の時間帯や受信するメッセージ内容などなどのコンテキストと応答時間の間に関係性が存在するかどうか、その特徴を把握する必要がある。そこで初めに、以下の属性と応答時間の関係性を調査する。

- メッセージの受信時間帯

表 2 得られた結果の例
Table 2 Example of answers.

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	1 人	停滞中	論文執筆	家	1 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	1 人	停滞中	テレビ	家	1 人	停滞中




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)
Fig. 3 The receipt time of message (left), The accompanied person of time which received message (right).




図 5 応答時間の頻度分布
Fig. 5 Frequency distribution of response time.




図 4 メッセージ受信時のコンテキストの割合
Fig. 4 Context of time which received message.




図 6 受信時間帯別の平均応答時間
Fig. 6 Average of response time with received time zones.

- メッセージ内容レベル
- メッセージ受信時の同行者
- メッセージ受信時の被験者の忙しさ
- メッセージ受信時のコンテキスト

4.1 メッセージの受信時間帯と応答時間の関係

メッセージの受信時間帯ごとの平均応答時間を図 6 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 40 分, 最大 10 時間, 最小 1 分以内), 昼の応答時間 (平均 41 分, 最大 6 時間 24 分, 最小 1 分以内), 夕の応答時間

(平均 43 分, 最大 4 時間 18 分, 最小 1 分以内) であった。1 要因の分散分析の結果, メッセージの受信時間帯により応答時間に有意差があることを確認している ($p < 0.01$)。また, 下位検定により, 朝と昼および朝と夜の間に有意差があることを確認しており ($p < 0.05$), 朝は応答時間が長くなることが確認された。この傾向は, 一般的に活動を始める朝の時間帯よりも, 1 日のタスクが落ち着き始める昼以降の方が, 与えられたタスクに対応しやすいからであると考え。この結果より, 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




図7 メッセージ内容レベル別平均応答時間

Fig. 7 Average of response time with message levels.




図8 メッセージ内容レベル別平均応答時間の頻度分布

Fig. 8 Frequency distribution of response time message levels.

ると考える。

4.2 メッセージ内容レベルと応答時間の関係

送信されたメッセージ内容レベルごとの平均応答時間を図7に示す。各レベルに対する平均応答時間は、1時間2分（レベル1）、53分（レベル2）、1時間9分（レベル3）であった。1要因の分散分析の結果、メッセージ内容レベル間で有意差は確認できなかった（ $p > 0.05$ ）。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、応答時間も短くなると考えられたが、結果は異なるものとなった。この原因を探るために、メッセージ内容レベル別平均応答時間の頻度分布を確認した（図8）。その結果、レベル2については応答時間が長くなるにつれて出現頻度が単調減少しているのに対して、レベル1では4時間から4時間以内、レベル3では1時間から4時間以内の頻度が多いことが確認された。

このことについて該当者にインタビューしたところ、レベル3のタスクについては、調べる時間が必要なためにその時間が確保できるまで応答しなかったとの回答が得られた。また、レベル1のタスクについては、「いつでも応答できる」簡単なタスクであるため、後回しにしたとのコメントが得られた。

また、図9にタスクの受信時間帯およびメッセージ内容レベル別の平均応答時間を示す。この図から、朝はどのようなレベルでも応答に要する時間が長くなっていることが




図9 受信時間帯およびメッセージ内容レベル別の平均応答時間

Fig. 9 Average of response time with received time zones and message levels.




図10 同行者およびメッセージ内容レベル別平均応答時間

Fig. 10 Average of response time with accompanied persons and message levels.

確認できる。一方、夕方はレベルごとにばらつきがみられる。夕方に限定したレベル別の1要因の分散分析の結果、レベルにより有意差があることを確認している（ $p < 0.05$ ）。また、下位検定により、レベル1とレベル2およびレベル2とレベル3の間に有意差があることを確認している（ $p < 0.05$ ）。このことから、夕方に限定した場合においては、メッセージ内容レベル2の応答時間が短くなると考えられる。これらのことから、応答時間の推定に利用することができると思う。

これらの結果より、応答時間とメッセージ内容レベルには単純な関係は存在しないが、メッセージ内容レベルにより応答時間の分布に特徴があることが分かった。他の要因を含めて分析することで、どのようなときに応答時間が長くなるのか明らかにすることができれば、応答時間の推定に利用できると考える。

4.3 同行者およびメッセージ内容レベルと応答時間の関係

図10に、同行者およびメッセージ内容レベル別の平均応答時間を示す。同行者を要因とする1要因の分散分析の結果、有意差は確認されなかった（ $p > 0.05$ ）。また、同行者およびメッセージ内容レベルを要因とする2要因の分散分析でも、同様の結果となった（ $p > 0.05$ ）。よって、同行




図 11 忙しさ別の平均応答時間

Fig. 11 Average of response time with busyness.

者による応答時間に対する直接的な影響はないと考える。ただし、図 10 をみると、1 人の場合はレベルごとの応答時間がほぼフラットなのに対して、同伴者がいる場合はメッセージ内容レベル間でばらつきが見られる。今後、データを増やすことでより詳細な分析を実施する必要があると考える。

4.4 忙しさと応答時間の関係

忙しさごとの平均応答時間を図 11^{*3}に示す。「とても忙しい」が最も応答時間が長くなっており、平均で約 2 時間となっている。一方、「暇」および「忙しい」が応答時間が短く、平均で約 30 分となっている。一元配置の分散分析の結果、忙しさにより応答時間に有意差があることを確認している ($p < 0.01$)。下位検定の結果、「とても忙しい」と「忙しい」および「とても忙しい」と「暇」の間に有意差があることを確認している ($p < 0.01$)。

「とても暇」については、直感的には一番応答時間が短くなると考えられるが、結果は「暇」や「忙しい」のほうが短い応答時間となった。

この結果を考察するにあたり、実験後被験者に対し、「とても暇」な時は返信できず、「暇」な時は返信できたケースができたのかについてインタビューしたところ、どうしても外せない作業中でない限り、少し「忙しい」ときの方が返しやすくと答えた被験者が多く存在した。割込みメッセージへの返信をタスクととらえた場合、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多く存在することが確認された。

4.5 メッセージ受信時のコンテキストと応答時間の関係

メッセージ受信時のコンテキスト別の平均応答時間を図 12^{*4}に示す。平均応答時間が最も長かったのは睡眠 (2 時間 45 分 50 秒) であり、最も短かったのは移動 (電車) (15 分 10 秒) である。移動の中では、移動 (電車) が最も短く、移動 (徒歩) (1 時間 20 分 12 秒) が一番長くなっ

^{*3} どちらもないと回答を得たケースが 2 件のみだったため、分析から除外している。図 11 の () 内はサンプル数を表している。

^{*4} サンプル件数が 5 件以上の項目のみ提示している。図 12 の () 内はサンプル数を表している。




図 12 メッセージ受信時のコンテキスト別の平均応答時間

Fig. 12 Average of response time with context of time which received message.

ている。1 要因の分散分析の結果、メッセージ受信時のコンテキストにより応答時間に有意差があることを確認している ($p < 0.01$)。下位検定の結果、睡眠時間と他の行動 (移動 (徒歩) を除く) との間に有意差を確認している ($p < 0.05$)。本結果からは、睡眠時は応答時間が長いという当たり前の結果しか主張できないが、サンプル数にばらつきが大きく、かつサンプル数が極端に少ないコンテキストもあるため、今後データを増やすことでより詳細な分析を実施する必要があると考える。

4.6 コンテキストデータと応答時間の関係

実験の結果より、応答時間は、受信時間帯が昼間以降になると短くなる傾向にあることが明らかになった。また、忙しさが忙しすぎるときに応答時間が長くなることは当然のことながら、「とても暇」なときにも応答時間が短くならないことが確認できた。また、メッセージ内容レベルと同行者による影響は直接的にはないことが確認されたが、他の要因と組み合わせることで応答時間が変化すると考えられる。これらのことから、より正確に応答時間を推定するためには、受信時間帯と忙しさだけでなく、複数の要素を複合的に組み合わせて推測する必要があると考える。そこで、次章ではこれらの要素からどの程度応答時間を推定できるのかを確認するために、複数のシナリオを想定して比較を行う。

5. 機械学習による応答者の推定

収集した受信者のコンテキストデータを用いて、応答の推定モデルを構築し、どの程度の精度で行えるかを検証する。そのためにいくつかのシナリオを想定して比較する。

5.1 推定条件とシナリオ

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、先の分析で用いた 4 属性 (メッセージ内容レベル、受信時間帯、同行者、忙しさ) に、受信者、行動カテゴリ、場所カテゴ

り、Moves のログを加えた以下の 8 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。なお、応答時間については、参加型センシングを想定し、すぐに返信が返ってくるかどうかの判定として、5 分以内に返信している場合を正解値とする 2 値に変換している。

- メッセージ内容レベル (3 種類: レベル 1, レベル 2, レベル 3)
- メッセージ受信時間帯 (3 種類: 朝, 昼, 夕)
- 同行者 (4 種類: 1 人, 家族, 同僚, 友人)
- 忙しさ (5 段階: とても忙しい～とても暇)
- 受信者 (9 人: A～I)
- 場所カテゴリ (8 種類: 自宅, 学校, 道路, 施設, レストランなど)
- Moves のログ (2 種類: 移動中, 停滞中)
- 行動カテゴリ (18 種類: 屋内活動, 屋外活動, 食事など)

モデル構築のデータセットには、先の分析に用いた計 198 件のデータセットを用いる。モデル構築のアルゴリズムには、代表的な機械学習アルゴリズムの 1 つである RandomForest を用いる。また、シナリオとして以下の 3 つを用いる。

シナリオ 1 (現在の状況) は、送信者がいつ・誰に・どのようなレベルのタスクを依頼するか情報のみが分かる状態を想定している。これは、受信者に対する情報がない状態であり、この場合は一般的な人の行動にあわせて、深夜早朝は避ける、よく答えてくれる人により重いレベルのタスクを依頼するなどの対応が考えられる。シナリオ 2 (現在利用可能) は、送信者がシナリオ 1 に加え、Moves から受信者がどこにいるかおよび移動中か停滞中かを判別できる状態を想定している。これは、現在利用可能なスマホアプリケーションを活用した状況を想定しており、プライバシーの保護など運用の問題はあるがすぐにでも実現可能な状態である。Moves のデータを利用することで、自宅や職場の判別や電車での移動などの状況が把握でき、これらの情報を用いることで、自宅にいる人や電車で移動中の人を選んでタスクを依頼できると考える。シナリオ 3 (将来利用可能) は、送信者が 8 属性すべてを正確に把握できた場合を想定している。これは、将来、センシング技術を駆使して受信者の状態をより詳細に把握できる状態を想定している。センシング技術の発展により、場所や移動の有無だけでなく、誰と一緒にいるのか、どんな行動をしているのかまで詳細に把握することで、同じ電車の移動中でも他者と一緒にいるときにはタスク依頼を控えたり、忙しさの程度にあわせてタスク依頼を行ったりすることができると考える。

シナリオ 1 では、メッセージ内容レベル、メッセージ受信時間帯、受信者の 3 属性を用いて応答モデルを構築す

表 3 シナリオ別評価結果

Table 3 Evaluation result of each scenarios.

シナリオ 1	Precision	Recall	F 値	応答あり 応答なし	
応答あり	0.404	0.348	0.374	23	43
応答なし	0.695	0.742	0.718	34	98
平均	0.598	0.611	0.603		
シナリオ 2	Precision	Recall	F 値	応答あり 応答なし	
応答あり	0.521	0.379	0.439	25	41
応答なし	0.727	0.826	0.773	23	109
平均	0.658	0.677	0.662		
シナリオ 3	Precision	Recall	F 値	応答あり 応答なし	
応答あり	0.586	0.515	0.548	34	32
応答なし	0.771	0.818	0.794	24	108
平均	0.710	0.717	0.712		

る。シナリオ 2 では、シナリオ 1 の属性に場所カテゴリ、Moves のログを加えた 5 属性を用いて応答モデルを構築する。シナリオ 3 では、8 属性すべてを用いて応答モデルを構築する。これら 3 つのシナリオを比較することで、ユーザのコンテキスト情報を用いた参加型センシングの効率化の可能性を検討する。

5.2 応答の推定結果

シナリオの比較結果を表 3 に示す。表 3 の左側は、各シナリオにおける Precision, Recall, F 値を示している。右側の表頭は推定値、表側は実測値を表している。効果的な参加型センシングでは、応答ありと推定した対象が実際にすばやく応答することが重要となる。そのため各シナリオにおける応答アリの Precision の値に注目する。シナリオ 1 では、応答ありと推定した 57 件中、23 件のみが実際に 5 分以内に応答しており、Precision は 40.4%となっている。シナリオ 2 では、応答ありと推定した 48 件中、25 件が実際に 5 分以内に応答しており、Precision は 52.1%となっている。シナリオ 3 では、応答ありと推定した 58 件中 34 件が実際に 5 分以内に応答しており、Precision は 58.6%となっている。

この結果から、シナリオ 3 のようにセンシングにより受信者の状況を送信者が詳細に把握できれば、より良いタイミングでタスクを依頼できると考えられる。また、シナリオ 2 の結果は、現状のアプリケーションの情報をうまく利用することだけでも 5 割以上の確率で応答を得られる可能性を示している。今回の実験では、5 分以内に応答を得られたのは、全体の約 3 割程度であった。このことから、タスクとコンテキストに対する応答モデルを構築することで、より高効率に参加型センシングが可能になると考える。

5.3 本実験の貢献と限界

本実験は、通常生活の中において、コンテキストと応答時間の関係を 2 週間にわたり、収集、分析したものである。被験者であることを被験者本人が認識するバイアスをなくすために、事前に実験であることを伝えない覆面調査であ

り、調査終了後に、2週間分の各応答時のコンテキストを申告してもらうことでグラントゥールズを得ている。調査ツールとして使用したLINEの返信時にどのような状態であったかをすべて思い出すことは、時間が経つにつれて困難になり、グラントゥールズの精度が劣化する。そのため、本実験は実験期間を2週間とし、記憶を手繰る補助としてMovesというライフログアプリを別の実験を装って導入してもらっていた。また、被験者、時間帯、レベルの組合せに対する応答がそれぞれ同等数となるように調査実施者側で管理しつつ、調査と気づかれないように各メッセージに返信対応する必要があることから、調査実施者の数に対する被験者の数には限界がある。今回は、2人で9人に対する調査を実施したが、非常に困難な作業であった。その結果、これまでにない貴重なデータが得られたと考えているが、この調査方法をより多くの被験者に対して、より多くの期間実施することは困難である。

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、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、送信時間帯、受信時の忙しさなどとの関係性を持つことが確認できた。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うえでの相関関係が存在すると考えられ、適切な割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198件のデータセットに対して3つのシナリオを設定・分析することで、どの程度の精度で応答の推定が可能であるかを検証した。その結果、応答の推定については、すべての属性情報がセンシングにより取得できると想定したシナリオ3の場合、58.6%という精度で応答の有無を推定でき、何も考慮しない状態(33.3%)やシナリオ1(40.4%)よりも大幅な改善が見込めることを確認した。より効果的な参加型センシングを行うためには、今回のような調査・実験の積み重ねが必要であり、参加型センシングの重要な参加者候補である学生を対象として収集した今回のデータおよび実験結果には一定の価値があると考ええる。

なお、今回の推定精度は実用面で見た場合、さらに向上が求められると考える。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のセンシングを検討する必要がある。また、今回の実験においては対象を学生に限定しているため、この結果がただちに参加型センシングの運営に適用できるわけではない。参加型センシングの参加者

には、学生だけでなく、会社員や主婦、お年寄りなどさまざまな立場の人が存在しており、異なるコンテキストと応答時間の関係を持っていると考えられる。さらに、参加型センシングにおけるタスクには、その場の天気や交通状況のように今回のメッセージレベル2またはレベル3に該当するようなタスク以外に、周辺地域の移動をともなう調査のようなより高いコストを必要とするタスクも存在する。本論文においてはこのようなタスクに対する検証はできておらず、今後さらなる調査が必要と考える。

最後に、5.1節におけるシナリオ2とシナリオ3の実現性に関して言及する。シナリオ2については、Movesから得られた移動中か停滞中かという情報を利用している。今回、調査であることを気付かれないように普段から利用するLINEを用いた結果、このような行動情報を別のアプリケーションで取得する必要があった。しかしながら、実際の参加型センシングでは、専用のアプリケーションをインストールすると想定でき、その中にMoves相当の機能を組み込めば十分に取得できる情報である。シナリオ3では、より詳細な行動情報を得る必要があるが、これは近年活発に研究が進められているスマートフォン内のセンサを用いた行動認識アルゴリズム[14]、[15]、[16]の進展によってある程度達成可能であると考えている。

謝辞 本研究は、戦略的情報通信研究開発推進事業(SCOPE)の研究成果である。

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?, *Proc. 9th Workshop on Mobile Computing Systems and Applications*, pp.11–16, ACM (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, *Proc. 7th ACM Conference on Embedded Networked Sensor Systems*, pp.349–350, ACM (2009).
- [4] 松田裕貴, 新井イスマイル: スマートフォン搭載照度センサの集合知による網羅的な街灯情報収集システムの開発, *情報処理学会論文誌*, Vol.55, No.2, pp.750–760 (2014).
- [5] Ueyama, Y., Tamai, M., Arakawa, Y. and Yasumoto, K.: Gamification-based incentive mechanism for participatory sensing, *2014 IEEE International Conference on Pervasive Computing and Communications Workshops (PERCOM Workshops)*, pp.98–103, IEEE (2014).
- [6] Arakawa, Y. and Matsuda, Y.: Gamification mechanism for enhancing a participatory urban sensing: Survey and practical results, *Journal of Information Processing*, in press.
- [7] Pejovic, V. and Musolesi, M.: InterruptMe: Designing intelligent prompting mechanisms for pervasive applica-

- tions, *Proc. 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing*, pp.897-908, ACM (2014).
- [8] Okoshi, T., Ramos, J., Nozaki, H., Nakazawa, J., Dey, A.K. and Tokuda, H.: Attelia: Reducing User's Cognitive Load due to Interruptive Notifications on Smart Phones, *Proc. IEEE International Conference on Pervasive Computing and Communications 2015 (PerCom '15)*, pp.96-104, ACM (2015).
 - [9] Perlow, L.A.: *Administrative science quarterly*, Vol.44, No.1, pp.57-81 (1999).
 - [10] Cutrell, E., Czerwinski, M. and Horvitz, E.: Notification, disruption, and memory: Effects of messaging interruptions on memory and performance (2001).
 - [11] Berry, M.J. and Linoff, G.: *Data mining techniques: For marketing, sales, and customer support*, John Wiley & Sons, Inc. (1997).
 - [12] 赤池勇磨, 荒川 豊, 諏訪博彦, 安本慶一: 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, 研究報告マルチメディア通信と分散処理, 情報処理学会, Vol.2015-MBL-75, No.9, pp.1-8 (2015).
 - [13] Hammer, J.C. and Yan, T.: Exploiting usage statistics for energy-efficient logical status inference on mobile phones, *Proc. 2014 ACM International Symposium on Wearable Computers*, pp.35-42, ACM (2014).
 - [14] Su, X., Tong, H. and Ji, P.: Accelerometer-based Activity Recognition on Smartphone, *Proc. 23rd ACM International Conference on Conference on Information and Knowledge Management*, pp.2021-2023, ACM (2014).
 - [15] Lee, Y.-S. and Cho, S.-B.: Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer, *Hybrid Artificial Intelligent Systems*, pp.460-467, Springer Berlin Heidelberg (2011).
 - [16] Ouchi, K. and Doi, M.: Indoor-outdoor activity recognition by a smartphone, *Proc. 2012 ACM Conference on Ubiquitous Computing*, pp.600-601, ACM (2012).



赤池 勇磨 (正会員)

2013 年立命館大学情報理工学部卒業。2015 年奈良先端科学技術大学院大学博士前期課程修了。現在、株式会社リクルートホールディングスネットビジネス本部社員。



荒川 豊 (正会員)

2001 年慶應義塾大学理工学部情報工学科卒業。2006 年同大学院博士課程修了。博士 (工学)。2006 年同大学特別研究助手 (2007 年より助教に変更)。2009 年九州大学大学院システム情報科学研究科助教。2011 年 EENSEEITH

訪問研究員。2012 年 DFKI 訪問研究員。2013 年より奈良先端科学技術大学院大学准教授。ネットワークアプリケーション, ソーシャルデータマイニングに関する研究に従事。IEEE, ACM, 電子情報通信学会各会員。



諏訪 博彦 (正会員)

1998 年群馬大学社会情報学部卒業。2006 年電気通信大学大学院情報システム学研究科博士後期課程修了。博士 (学術)。2006 年同大学院助手 (2007 年より助教に変更)。2014 年 10 月より奈良先端科学技術大学院大学助教。

社会情報システムに関する研究に従事。社会情報学会, 人工知能学会, 電子情報通信学会各会員。



安本 慶一 (正会員)

1991 年大阪大学基礎工学部情報工学科卒業。1995 年同大学院博士後期課程退学後、滋賀大学経済学部助手。2002 年奈良先端科学技術大学院大学情報科学研究科助教授, 2011 年より同研究科教授。博士 (工学)。モバイルコン

ピューティング, ユビキタスコンピューティングに関する研究に従事。電子情報通信学会, ACM, IEEE 各会員。