

道路政策の質の向上に資する技術研究開発

【研究状況報告書（2年目の研究対象）】

| | | | | | |
|---|------|--|-----------|----------------|--------|
| ①研究代表者 | | 氏名（ふりがな） | 所属 | 役職 | |
| | | ちから いし まこと 力 石 真 | 広島大学 | 准教授 | |
| ②研究 テーマ | 名称 | AI技術に基づく短期交通予測手法と総合的な交通需要マネジメントの研究開発 | | | |
| | 政策領域 | [主領域] 新たな情報サービスと利用者満足度向上 | 公募 タイプ | タイプIV ソフト分野 | |
| | | [副領域] 新たな行政システム | | | |
| ③研究経費（単位：万円） | | 平成30年度 | 令和元年度 | 令和2年度 | 総合計 |
| ※H30は精算額、R1は受託額、R2は計画額を記入。端数切捨。 | | 4,769 | 4,899 | 4,500 | 14,168 |
| ④研究者氏名 | | （研究代表者以外の主な研究者の氏名、所属・役職を記入。なお、記入欄が足りない場合は適宜追加下さい。） | | | |
| 氏名 | | 所属・役職 | | | |
| 浦田淳司 | | 東京大学・助教 | | | |
| 美添一樹 | | 理化学研究所・探索と並列計算ユニットリーダー | | | |
| 円山琢也 | | 熊本大学・准教授 | | | |
| 塩見康博 | | 立命館大学・准教授 | | | |
| 早川 敬一郎 | | ㈱豊田中央研究所・プログラママネージャー | | | |
| Varun Varghese | | 広島大学・研究員 | | | |
| ⑤研究の目的・目標（提案書に記載した研究の目的・目標を簡潔に記入。） | | | | | |
| <p>本研究では、多様な交通サービス供給主体が協調する交通市場の実現に向けて、その要となる短期交通需要予測技術を開発し、開発した予測技術を下敷きとした総合的な交通需要マネジメント手法を提案する。具体的には、交通関連データを最大限活用するための学習アルゴリズムの開発と、そのアウトプット（短期予測およびそれに基づく交通需要マネジメント）の有用性を示すことを通じて、交通分野におけるAI技術の社会実装に資する知見を提供する。2019年度の研究概要を図1に示す。本年度は、深層学習／転移学習手法を用いた交通状態及びOD交通需要の短期予測【短期交通予測】、及び、動的プライシング、ライドヘイリングを含むICT利用に起因する行動変容の把握に焦点を当てたプローブパーソン-選好意識調査（PP-SP調査）【選考情報の抽出】について研究を進める。</p> | | | | | |

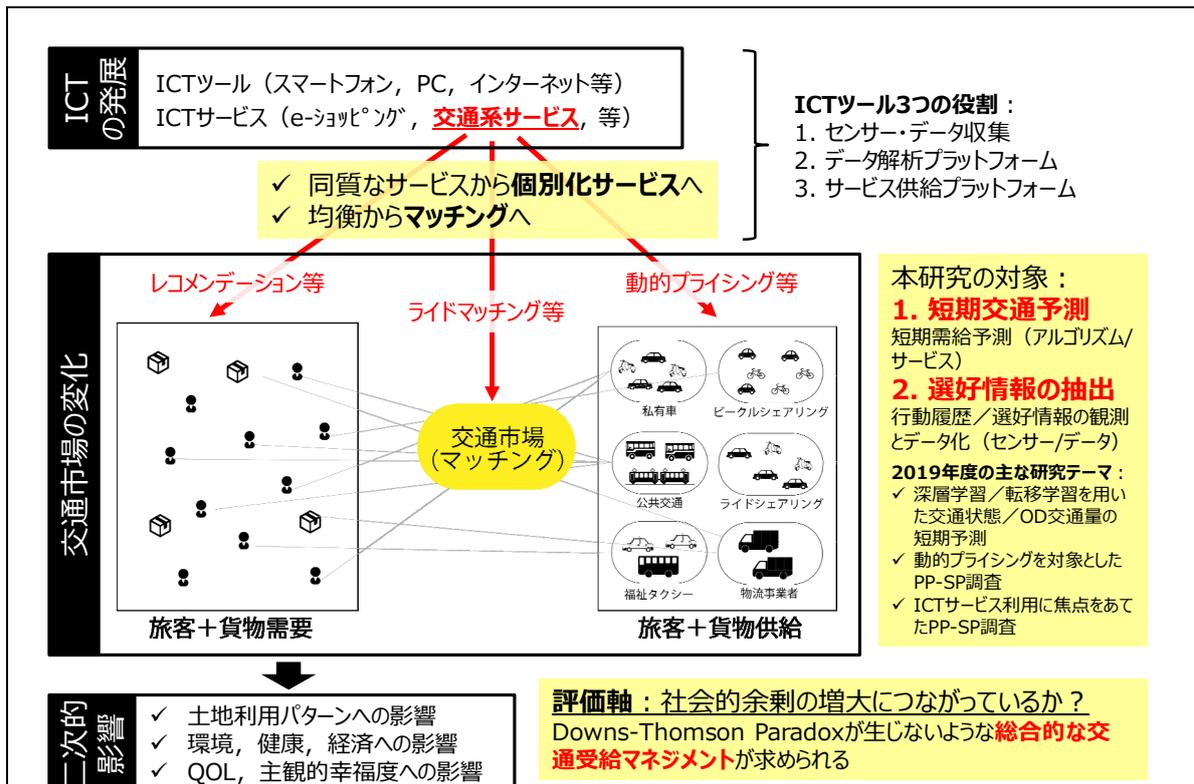


図 1. 2019 年度研究の位置付け

⑥これまでの研究経過

(研究の進捗状況について、これまでに得られた研究成果や目標の達成状況とその根拠(データ等)を必要に応じて図表等を用いながら具体的に記入。)

(1) リンク交通量, 時間占有率の短期予測

- ✓ 研究背景・目的：平成30年7月豪雨災害後、広島県広島市と呉市をつなぐ国道31号において慢性的な交通渋滞が発生した。流入制御や経路誘導といった災害時の交通マネジメント施策を効率的に実施するためには、精度の高い交通量や時間占有率の短期予測手法の開発が重要であるとの認識のもと、昨年度の研究では、深層学習の利用により短期予測の精度改善が達成できることを確認している。本年度は、昨年度の研究成果を基礎に、以下の2点について検討を加えた。

1. 機械学習手法は、交通流理論が示唆するメカニズムを模倣できているか？
2. 転移学習の適用により予測精度はどの程度改善するか？

計算速度改善のため、全ての計算において理化学研究所が保有する計算機システムRAIDENを利用した。

- ✓ データ：3年分の広島県警トラカデータ。分析対象区間は図2のとおり。
- ✓ 結果 1：機械学習手法は交通理論が示唆するメカニズムを模倣するか？
交通短期予測の文脈において広く使われている以下の7つのモデル（Random Forest (RF), Support Vector Machine (SVM), XGBoost (XGB), Shallow feed-forward neural network (FFNN), Deep feed-forward neural network (DNN), ARIMAモデル, VARモデル）の挙動が一般的な渋滞メカニズムを再現しているかどうか（すなわ

ち、ある地点の時間占有率は、上流側からの交通量、及び、下流側の時間占有率により影響を受けることがモデルにより表現されているかどうか)を災害前、災害発生直後、災害発生1.5カ月後各々について確認した。具体的には図2のloop 9及びloop 18の交通量、時間占有率を出力、全22箇所の交通量及び時間占有率を入力とするモデルを作成した。得られた主要な知見は以下のとおりである。

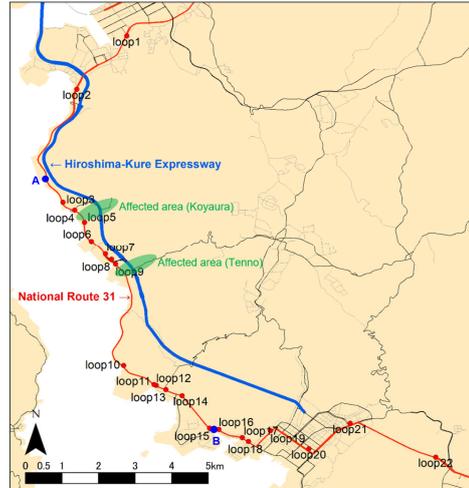


図2. 予測対象区間 (A点—B点)

1. 機械学習手法を用いる場合、時間占有率については期間に関わらず一定の予測精度を確保することができる一方、交通量については特に災害期間中の予測精度が低下する(表1参照)。
2. データの量が限られている場合、深層学習よりも他の機械学習手法(特にXGBoost)の方が高い予測精度を示す傾向にある。
3. 予測精度が高い手法(XGBoost)が常に交通渋滞の発生メカニズムを模倣しているとは限らない。実証分析では、最も高い予測精度を示すXGBoostに比べて予測精度の低い深層学習の方が渋滞発生メカニズムと比較的整合する挙動を示す(すなわち、ある地点の時間占有率は、上流側に位置する感知器の交通量、及び、下流側に位置する感知器の時間占有率に影響を受ける)ことを確認。

✓ 結果2：転移学習による予測精度の改善

- ✓ 災害時においては、Covariate shift(例：災害前では観測されなかったようなひどい渋滞が発生する)やConcept shift(例：災害前と同程度の流入交通量であっても渋滞が発生する)が生じるため、災害後に得られる少量のデータを有効に活用する枠組みを採用することが望ましい。本研究では、災害前に得られた比較的大規模のデータを用いて構築したモデルを災害後に得られたデータを使用し更新する転移学習の有効性を実証的に検証した。比較したモデルは以下のとおり：Dense Neural Networks, LSTM-RNN (Long short term memory Recurrent Neural Network), AE-LSTM (Auto encoder LSTM), Bidirectional LSTM (BLSTM), GRU (Gated Recurrent Unit), CNN (Convolutional Neural Network), CNN-LSTM, CNN-BLSTM。得られた主要な知見は以下のとおりである。

1. 時空間データの取り扱いに優れるCNN-BLSTMの予測精度が高い傾向にある。
2. CNNレイヤのパラメータは固定し、BLSTMレイヤのパラメータのみ災害後のデータを用いて更新した場合に更に予測精度は向上する。
3. ファインチューニングにより推定精度が改善することを確認(表2)。正則化項導入による精度改善は限定的。転移学習に用いる学習データは、検証データの期間に近いほど精度改善がみられることを確認。特に災害時等においては、新たなデータを入手する度に継続的にモデルを更新し続けることの重要性を示唆。

表1. 交通量及び時間占有率の予測精度の比較

| 対象 期間 | Time Method | 5分先の予測 | | 10分先の予測 | | 20分先の予測 | |
|-----------------------|----------------|----------------------|----------------------|----------------------|----------------------|----------------------|----------------------|
| | | 交通量 | 時間占有率 | 交通量 | 時間占有率 | 交通量 | 時間占有率 |
| | | R ² (MAE) |
| 2018年 7月 1-5日 | ARIMA | 0.86 (0.27) | 0.87 (0.25) | 0.81 (0.32) | 0.81 (0.31) | 0.74 (0.38) | 0.72 (0.40) |
| | VAR | 0.80 (0.30) | 0.83 (0.27) | 0.73 (0.35) | 0.75 (0.33) | 0.66 (0.39) | 0.63 (0.38) |
| | RF | 0.87 (0.22) | 0.89 (0.21) | 0.83 (0.27) | 0.85 (0.25) | 0.82 (0.27) | 0.84 (0.26) |
| | SVM | 0.85 (0.24) | 0.85 (0.24) | 0.83 (0.26) | 0.83 (0.26) | 0.81 (0.29) | 0.80 (0.29) |
| | XGB | 0.87 (0.23) | 0.88 (0.22) | 0.83 (0.27) | 0.85 (0.25) | 0.81 (0.29) | 0.82 (0.28) |
| | FFNN | 0.74 (0.34) | 0.75 (0.35) | 0.66 (0.40) | 0.74 (0.35) | 0.75 (0.36) | 0.71 (0.39) |
| | DNN | 0.83 (0.28) | 0.85 (0.27) | 0.80 (0.32) | 0.79 (0.31) | 0.74 (0.37) | 0.77 (0.34) |
| 2018年 7月 12-18日 | ARIMA | 0.77 (0.31) | 0.91 (0.20) | 0.68 (0.39) | 0.84 (0.27) | 0.60 (0.45) | 0.75 (0.34) |
| | VAR | 0.65 (0.45) | 0.88 (0.25) | 0.57 (0.50) | 0.83 (0.30) | 0.53 (0.51) | 0.73 (0.34) |
| | RF | 0.80 (0.31) | 0.93 (0.18) | 0.77 (0.36) | 0.90 (0.21) | 0.75 (0.38) | 0.87 (0.26) |
| | SVM | 0.78 (0.35) | 0.88 (0.26) | 0.76 (0.37) | 0.85 (0.30) | 0.75 (0.39) | 0.79 (0.34) |
| | XGB | 0.82 (0.29) | 0.94 (0.17) | 0.79 (0.33) | 0.91 (0.21) | 0.82 (0.29) | 0.94 (0.17) |
| | FFNN | 0.72 (0.42) | 0.86 (0.28) | 0.72 (0.41) | 0.83 (0.32) | 0.70 (0.42) | 0.76 (0.37) |
| | DNN | 0.79 (0.35) | 0.89 (0.26) | 0.76 (0.40) | 0.84 (0.31) | 0.69 (0.44) | 0.74 (0.39) |
| 2018年 8月 20-26日 | ARIMA | 0.76 (0.34) | 0.90 (0.24) | 0.70 (0.41) | 0.84 (0.30) | 0.65 (0.45) | 0.76 (0.37) |
| | VAR | 0.67 (0.40) | 0.82 (0.27) | 0.61 (0.45) | 0.76 (0.31) | 0.30 (0.45) | 0.45 (0.36) |
| | RF | 0.84 (0.25) | 0.90 (0.19) | 0.82 (0.29) | 0.87 (0.23) | 0.82 (0.30) | 0.83 (0.26) |
| | SVM | 0.80 (0.31) | 0.87 (0.23) | 0.77 (0.35) | 0.84 (0.26) | 0.74 (0.38) | 0.81 (0.29) |
| | XGB | 0.83 (0.27) | 0.90 (0.19) | 0.82 (0.29) | 0.87 (0.23) | 0.81 (0.31) | 0.82 (0.27) |
| | FFNN | 0.78 (0.32) | 0.84 (0.25) | 0.52 (0.51) | 0.79 (0.30) | 0.71 (0.38) | 0.77 (0.32) |
| | DNN | 0.79 (0.32) | 0.86 (0.23) | 0.71 (0.39) | 0.80 (0.28) | 0.70 (0.41) | 0.70 (0.37) |

Note: A represents the period before the disaster i.e. from July 1 to 5, 2018.
 B represents the period immediately after the disaster i.e. July 12 to 18, 2018.
 C represents the period after the disaster i.e. August 20-26, 2018.

表2. 転移学習を実行した場合のCNN-BLSTMの予測精度(MAPE)の改善

| 元ドメイン | 災害前2年間のトラカンデータ (178カ所) | | | | | |
|--|--------------------------|-------------------------|--------------------------|---------------------------|----------------------------|----------------------------|
| 目標ドメイン (学習データ) | 7/12-18 (発災後 1週間) | 7/12-18 (発災後 1週間) | 7/19-25 (発災後 2週間) | 7/12-25 (発災後 1-2週間) | 7/26-8/8 (発災後 3-4週間) | 7/12-8/8 (発災後 1-4週間) |
| 目標ドメイン (検証データ) | 7/26-8/2 (発災後 3週間) | 7/19-25 (発災後 2週間) | 7/26-8/2 (発災後 3週間) | 7/26-8/2 (発災後 3週間) | 8/9-15 (発災後 5週間) | 8/9-15 (発災後 5週間) |
| 学習の種類 (数字は MAPE) | | | | | | |
| ファインチューニングなし(元 ドメイン+目標ドメイン(学習 データ)で学習) | 38.677 | 22.631 | 34.864 | 30.718 | 23.440 | 30.009 |
| ファインチューニングあり (正則化項無) | 19.257 | 18.142 | 22.501 | 22.211 | 16.215 | 16.838 |
| ファインチューニングあり (正則化項有) | 19.108 | 18.101 | 21.422 | 22.211 | 17.265 | 16.097 |

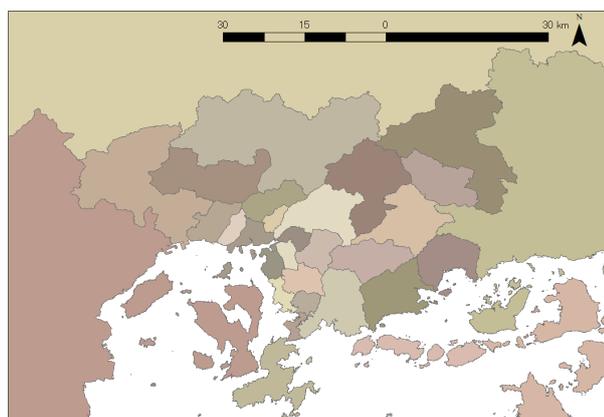
(2) OD交通量の短期予測

- ✓ **研究背景・目的**：特に交通ネットワーク被災時など、限られた交通インフラを効率的に利用するためには臨時交通サービスの設計や流入制御に資する短期交通予測手法の確立が求められる。以上から、本研究では、携帯電話の位置情報データ（モバイル空間統計データ）を使用し、前日同時刻までのデータから、24時間後のOD交通量を予測するモデルを複数構築しその精度を比較した（ゾーンサイズは図3に示すとおり）。比較に用いた深層学習モデルは、RNN (Recurrent neural network), GRU (Gated Recurrent Unit), GRU+Dropout, LSTM (Long Short term Memory), LSTM + Dropoutの5種類であり、出力は特定のODペアの交通量、入力は当該ODペアの交通量、逆向きのODペアの交通量、平日/休日ダミーである。予測対象期間は表3に示す4期間を設定した。予測精度の比較結果を表4に、予測誤差を図4に示す。得られた主要な知見は以下のとおりである。
1. 発災前、発災後いずれのケースにおいても、各層のニューロン数の増加やドロップアウト（過学習を防ぐ目的で、学習時にニューロン間のつながりをランダムに削除する手法）の導入による予測精度の改善はほとんど確認されない。また、被災直後を除き、過去のOD交通量の外挿に基づく予測の方が高い精度を示すケースを確認した。サンプル数が限られている場合、大きな学習モデルを構築しネットワーク構造に工夫を施してもほとんど予測精度の改善に寄与しないことを示唆。
 2. 一方、被災直後の規則性の低いOD交通量の予測（2018年8月のOD交通量の予測）については、サンプル数が少ない場合でも深層学習の適用により一定の予測精度の改善がみられることを確認。

表3. 使用したデータセット

| 期間 | データの 種類 | データセット |
|--------------------|------------|-----------|
| 1. 災害前 (1710) | 学習 | 2017年6-9月 |
| | 検証 | 2017年10月 |
| 2. 災害後 1 (1810) | 学習 | 2018年6-9月 |
| | 検証 | 2018年10月 |
| 3. 災害後 2 (1809) | 学習 | 2018年6-8月 |
| | 検証 | 2018年9月 |
| 4. 災害後 3 (1808) | 学習 | 2018年6-7月 |
| | 検証 | 2018年8月 |

図3. 予測対象エリアのゾーン区分



注：網掛は平均絶対誤差が300以下。

表4. OD交通量の予測精度の比較

| Method | Num. of hidden | Dropout | Input (day) | Test: 1710 | | Test: 1810 | |
|--------|----------------|---------|-------------|------------|-----|------------|-----|
| | | | | RMSE | MAE | RMSE | MAE |
| Base | | | | 452 | 272 | 608 | 340 |
| RNN | 80 | | 4 | 423 | 320 | 386 | 251 |
| | 80 | apply | 4 | 1000 | 794 | 804 | 605 |
| | 80 | | 5 | 404 | 312 | 456 | 299 |
| | 100 | | 4 | 381 | 261 | 436 | 310 |
| | 100 | apply | 4 | 974 | 753 | 523 | 326 |
| | 100 | | 5 | 502 | 373 | 618 | 411 |
| LSTM | 80 | | 4 | 359 | 242 | 419 | 287 |
| | 80 | apply | 4 | 481 | 327 | 702 | 453 |
| | 80 | | 5 | 494 | 368 | 460 | 340 |
| | 100 | | 4 | 342 | 229 | 338 | 230 |
| | 100 | apply | 4 | 537 | 376 | 659 | 400 |
| | 100 | | 5 | 558 | 357 | 411 | 302 |
| GRU | 120 | | 5 | 498 | 367 | 446 | 327 |
| | 80 | | 4 | 407 | 259 | 369 | 248 |
| | 80 | apply | 4 | 610 | 445 | 744 | 551 |
| | 80 | | 5 | 802 | 614 | 470 | 329 |
| | 100 | | 4 | 486 | 297 | 394 | 273 |
| | 100 | apply | 4 | 509 | 380 | 735 | 526 |
| | 100 | | 5 | 518 | 363 | 433 | 306 |
| | 120 | | 5 | 535 | 367 | 376 | 264 |

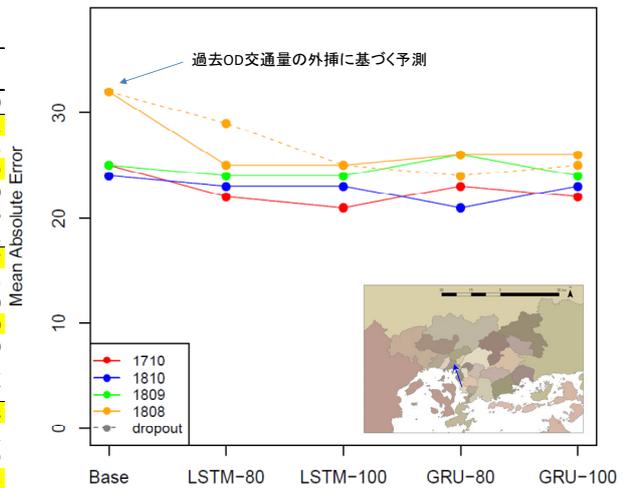


図4. 呉市天応—広島市南区間OD交通量予測時の平均絶対誤差

(3) PP-SP調査による動的プライシングの影響評価

- ✓ **研究背景・目的:** 混雑課金導入の影響は、スケジュール制約等、各トリップの背景にある文脈要因の影響を受けることが想定される。そこで本研究では、(1)トリップを実行した際の分脈要因の存在を前提に混雑課金導入時の行動変容について被験者に回答してもらう調査手法を構築し、(2) 実証分析を通じて文脈要因の影響を把握する。

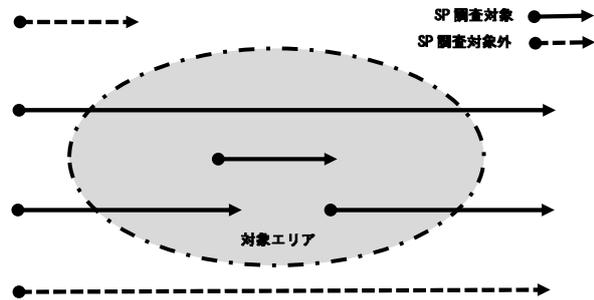


図5. SP調査対象の判定イメージ

- ✓ **調査の特徴:** 調査の特徴は以下の通り。

1. 既存のプローブパーソン調査アプリ（トランスフィールド社製）をベースに、ある特定の課金エリアを自動車で流入／通過／流出した場合に混雑課金導入時（コードン課金／対距離課金を想定）の行動変容に関するSP設問を尋ねる仕組みを導入（図5の判定イメージ参照）。課金エリアを通過するトリップ完了直後に回答を依頼することにより、記憶の劣化に伴う回答値の信頼性低下を抑制。
2. SP設問の設計はPivoted SP型の設問として設定。具体的には、課金エリア内の実走行時間により表示されるSP水準が異なる仕組みを導入（SP設問提示例は図6参照）。



図6. SP設問提示例

✓ 実証調査概要 :

1. 調査時期：2020年1月20日-2月9日（被験者当たり2週間調査に参加）
2. 調査対象エリア：広島市・熊本市（課金対象エリアは図7参照）
3. 被験者数：広島市，熊本市，各100名
4. 被験者の属性：課金対象エリアに週3日以上自動車での移動がある個人



図7. 設定した混雑課金対象エリア
(左：広島市，右：熊本市)

✓ 今後の分析予定 :

1. SP調査回答タイミングがSP設問回答の質に及ぼす影響評価
2. 混雑課金導入に伴う行動変容パターンの把握及びそのモデル化
3. Recursive logit型生活行動モデルを用いたシミュレーション分析

(4) PP-SP調査によるICT利用が生活行動に及ぼす影響評価

- ✓ **究背景・目的**：米国や中国，東南アジア諸国では，配車に加え，買物代行や掃除代行，食事の配達など，様々なサービスが統一されたプラットフォーム上で利用できるアプリが普及している．こういったアプリの普及は，レストランやショップの運営形態や土地利用にまで影響を及ぼしている．今後，我が国における配車サービスの導入方針を検討する際には，このような波及効果を踏まえた意思決定を行うことが求められる．本研究では，GO-JEKをはじめとする配車アプリが広く普及しているインドネシア・ジャカルタ市を対象に，ICT利用が生活行動に及ぼす影響を評価するためのPP-SP調査を実施する．
- ✓ **調査の特徴**：調査の特徴は以下の通り．
 1. 既存のプロブパーソン調査アプリ（Mobile Market Monitor(MMM)社製．図8参照）をベースに，ICT利用（配車サービス，e-shopping，デリバリーサービス等の利用）に関連する行動履歴を把握できるようアプリを改良．
 2. 「買物」，「食事」，「移動」については，トリップの代替可能性が高いことから，**e-サービス改善時の行動変容**に関するSP設問を提示．また，e-サービスを利用した個人に対しては，e-サービスが利用できない場合の行動（店舗に出向くか，購入をあきらめるか）に関する意識調査を実施．
 3. SP設問の設計はPivoted SP型の設問として設定．具体的には，**移動時間，移動費用，食費などのRPデータからSPの水準を生成する仕組みを導入**（SP設問提示例は図9参照）．

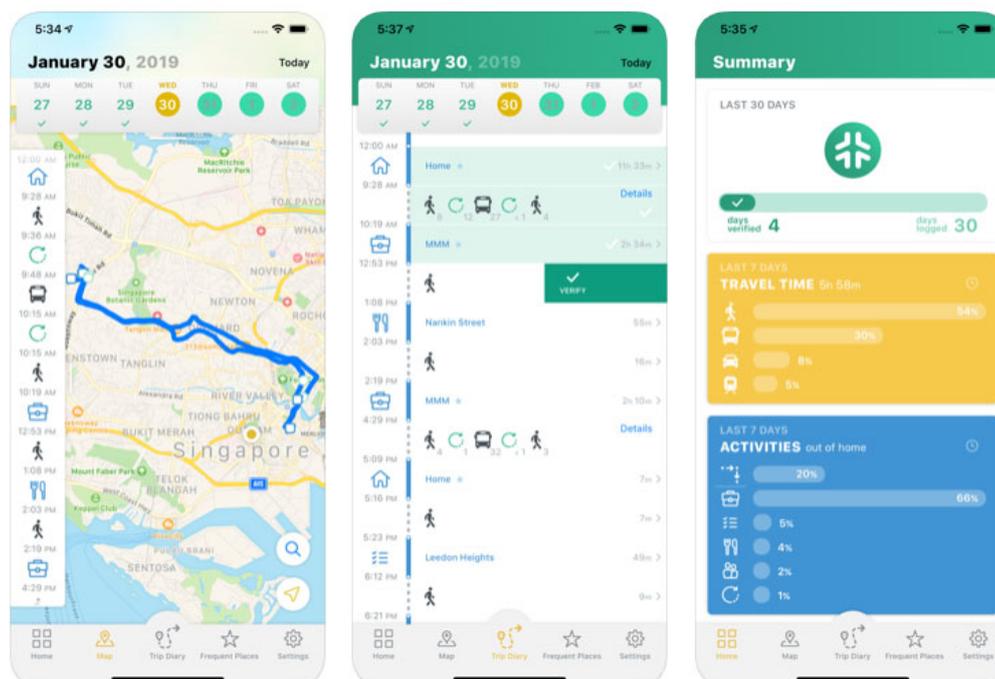


図8. MMM社製のアプリ画面

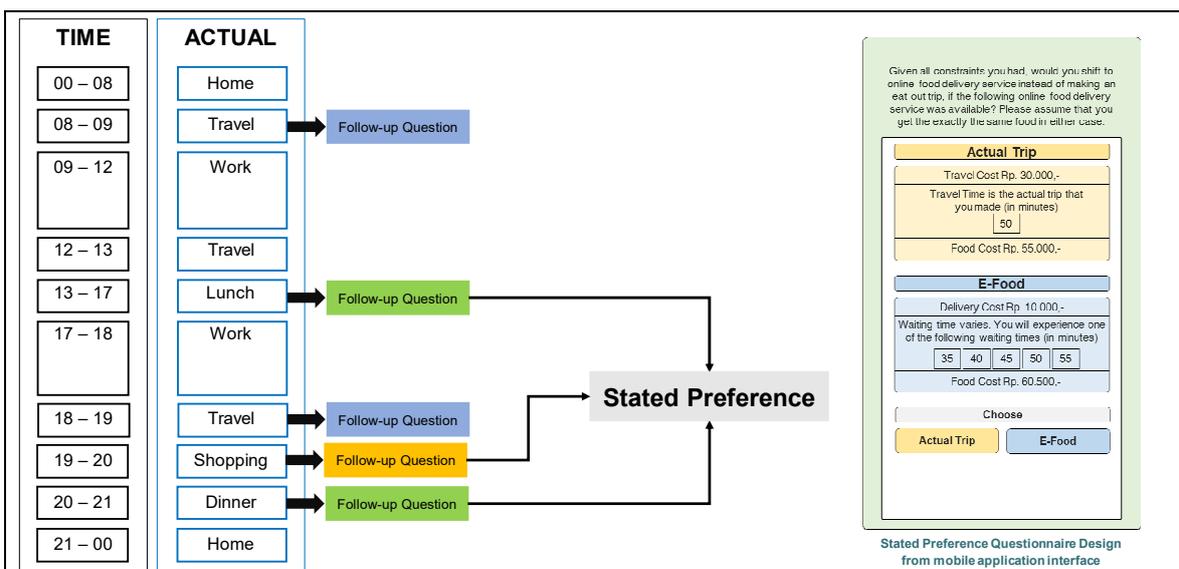


図9. SP設問提示例

✓ 実証調査概要 :

1. 調査時期：2020年1月21日-2月3日（2週間のPP調査）
2. 調査対象エリア：インドネシア・ジャカルタ市
3. 被験者数：300名
4. 被験者の属性：South Jakartaに在住又は通勤するGO-JEKユーザー

✓ 今後の分析予定 :

1. ICT利用による活動の代替／補完関係に関するモデル分析
2. e-サービス改善に伴う行動変容に関するシミュレーション分析
3. e-サービス導入に伴う土地利用への影響に関する基礎分析

(5) その他

研究を進めるにつれ新たに出てきた研究課題についても一部検討を加えた。以下、結果／進捗状況の概要を報告する。

5.1. 道路ネットワークの脆弱性

- ✓ 概要: 短期予測の実証分析として扱っている平成30年7月豪雨時の分析がどの程度一般性を有するのか、平成30年7月豪雨時のような道路ネットワークの途絶とサービスの低下はどの地域においても起こり得るのか、について検証するために、全国69都市の道路ネットワークの脆弱性評価を実施した。分析の結果、現在使用している指標（道路ネットワークの途絶に伴う最短経路旅行時間の増大）に基づくと、呉市は69都市中最もパフォーマンスの悪い都市のひとつであることが確認された（図10参照）。
- ✓ 今後の予定：道路ネットワークをランダムに切断する方法から、実際の土砂災害発生リスクに基づくネットワークの切断方法に改善予定。

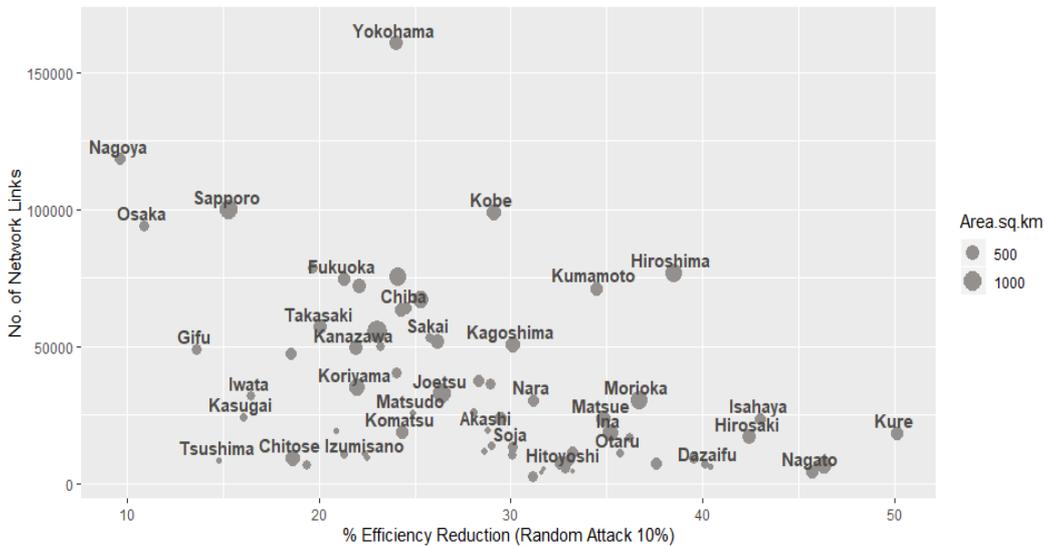


図10. 10%の道路リンクをランダムに切断した場合の道路ネットワークの脆弱性

5.2. 災害時の出発時刻選択に関するSP調査手法の改善

- ✓ **概要**：災害時の選好情報を抽出する手法として、災害時の出発時刻選択に関するSP調査手法について検討した。図11に示すアルゴリズムに基づきSP属性を設定することで、災害時に生じた旅行時間の増大時の出発時刻選好の観測が可能。

SP設問の生成過程

乱数の発生

- $p_1 \leftarrow [6, 7, 8, 9, 10]$ からランダムに1つ選択してください。
- $p_2 \leftarrow [7, 8, 9]$ からランダムに1つ選択してください。
- $p_3 \leftarrow [2, 3, 4]$ からランダムに1つ選択してください。
- $p_4 \leftarrow [0.1, 0.2]$ からランダムに1つ選択してください。
- $p_5 \leftarrow [1, 2, 3]$ からランダムに1つ選択してください。
- $p_6 \leftarrow [1, 2, 3]$ からランダムに1つ選択してください。
- $p_7 \leftarrow$ 一様分布(最小0.9, 最大0.99)からランダムに1つ選択してください。
- $p_8 \leftarrow$ 一様分布(最小0.6, 最大0.89)からランダムに1つ選択してください。

各変数の定義

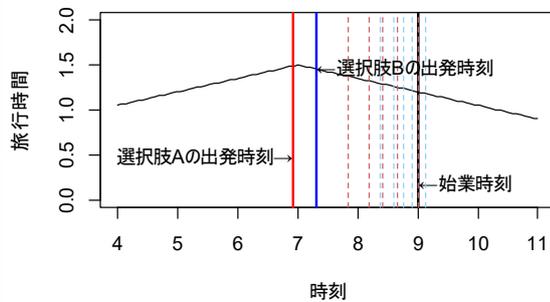
始業時刻 $S = p_1$
 旅行時間ピーク時刻 $P = p_2$
 ピーク時刻の旅行時間 $T = [$ 問9の回答値 $]$ $\times p_3$
 旅行時間の傾き(ピーク時刻への交通集中の程度を表現) $\alpha = T \times p_4$
 出発時刻が t 時の平均旅行時間 $f(t) = \begin{cases} T & (P = t \text{ の場合}) \\ T - \alpha(P - t) & (t < P \text{ の場合}) \\ T - \alpha(t - P) & (t > P \text{ の場合}) \end{cases}$
 選択肢(A)の旅行時間の分散 $\sigma_A = T \times p_5 + 10$
 選択肢(B)の旅行時間の分散 $\sigma_B = T \times p_6 + 10$
 平均旅行時間で移動した場合に時刻 S に到着する場合の出発時刻: $t_{out} = \begin{cases} S - T & (P + T = S \text{ の場合}) \\ \frac{S - T + \alpha P}{1 - \alpha} & (P + T > S \text{ の場合}) \\ \frac{S - T - \alpha P}{1 - \alpha} & (P + T < S \text{ の場合}) \end{cases}$
 選択肢(A)の選着回避度合い $\beta_A =$ 正規分布 $N(0, \sigma_A^2)$ の p_7 パーセンタイル値
 選択肢(B)の選着回避度合い $\beta_B =$ 正規分布 $N(0, \sigma_B^2)$ の p_8 パーセンタイル値

選択肢(A)の到着時刻分布：
 $arrA10 =$ 正規分布 $N(S - \beta_A, \sigma_A \times (f(t_{arr} - \beta_A)/T))$ の10パーセンタイル値
 $arrA30 =$ 正規分布 $N(S - \beta_A, \sigma_A \times (f(t_{arr} - \beta_A)/T))$ の30パーセンタイル値
 $arrA50 =$ 正規分布 $N(S - \beta_A, \sigma_A \times (f(t_{arr} - \beta_A)/T))$ の50パーセンタイル値
 $arrA70 =$ 正規分布 $N(S - \beta_A, \sigma_A \times (f(t_{arr} - \beta_A)/T))$ の70パーセンタイル値
 $arrA90 =$ 正規分布 $N(S - \beta_A, \sigma_A \times (f(t_{arr} - \beta_A)/T))$ の90パーセンタイル値

選択肢(B)の到着時刻分布：
 $arrB10 =$ 正規分布 $N(S - \beta_B, \sigma_B \times (f(t_{arr} - \beta_B)/T))$ の10パーセンタイル値
 $arrB30 =$ 正規分布 $N(S - \beta_B, \sigma_B \times (f(t_{arr} - \beta_B)/T))$ の30パーセンタイル値
 $arrB50 =$ 正規分布 $N(S - \beta_B, \sigma_B \times (f(t_{arr} - \beta_B)/T))$ の50パーセンタイル値
 $arrB70 =$ 正規分布 $N(S - \beta_B, \sigma_B \times (f(t_{arr} - \beta_B)/T))$ の70パーセンタイル値
 $arrB90 =$ 正規分布 $N(S - \beta_B, \sigma_B \times (f(t_{arr} - \beta_B)/T))$ の90パーセンタイル値

選択肢(A)の出発時刻 $t_A = arrA50 - f(t_{arr} - \beta_A)$
 選択肢(B)の出発時刻 $t_B = arrB50 - f(t_{arr} - \beta_B)$

仮想的に生成した選択肢と旅行時間分布



SP設問

(1) 通勤時間に関して以下の特徴がある場合、(A)、(B)のどちらの時刻に出発したいですか。

<出発時刻(A)と(B)の特徴>
 始業時刻は $[S]$ 時とします。
 出発時刻(A)と(B)における通勤にかかる旅行時間と到着時刻は、渋滞状況によって変動する可能性があります。

以下のカードに示す5つの旅行時間と到着時刻の特徴が等しい確率で起こります。

| 到着時刻 | 旅行時間 | 到着時刻 | 旅行時間 |
|--------------------|--------------------|--------------------|--------------------|
| 5 時に1回は始業時刻の0分〇に到着 | $[arrA10 - t_A]$ 分 | 5 時に1回は始業時刻の0分〇に到着 | $[arrB10 - t_B]$ 分 |
| 5 時に1回は始業時刻の0分〇に到着 | $[arrA30 - t_A]$ 分 | 5 時に1回は始業時刻の0分〇に到着 | $[arrB30 - t_B]$ 分 |
| 5 時に1回は始業時刻の0分〇に到着 | $[arrA50 - t_A]$ 分 | 5 時に1回は始業時刻の0分〇に到着 | $[arrB50 - t_B]$ 分 |
| 5 時に1回は始業時刻の0分〇に到着 | $[arrA70 - t_A]$ 分 | 5 時に1回は始業時刻の0分〇に到着 | $[arrB70 - t_B]$ 分 |
| 5 時に1回は始業時刻の0分〇に到着 | $[arrA90 - t_A]$ 分 | 5 時に1回は始業時刻の0分〇に到着 | $[arrB90 - t_B]$ 分 |

出発時刻(A) $[t_A]$ 平均旅行時間: $[f(t_{arr} - \beta_A)]$
 出発時刻(B) $[t_B]$ 平均旅行時間: $[f(t_{arr} - \beta_B)]$

図11. 災害時の出発時刻選択に関するSP調査の設計

⑦研究成果の発表状況

(本研究から得られた研究成果について、学術誌等に発表した論文及び国際会議、学会等における発表等があれば記入。)

発表済／受理済

1. Chikaraishi, M., Watanabe, R., Varghese, V., Urata, J., Yoshizoe, K., Shiomi, Y. (2019) On the possibility of short-term traffic forecasting under road network disruption: A case study of Hiroshima, Japan, presented in the 15th World Conference on Transport Research, May 2019, Mumbai, India.
2. Urata, J., Chikaraishi, M. (2019) Application of Deep Learning to Destination Choice for Improving Predictability and Generating a Choice Set, International Choice Modelling Conference 2019, 19-21 August, Kobe, Japan.
3. Varghese, V., Chikaraishi, M., Urata, J. (2019) Big data, deep learning, and transportation: A meta-analysis, Paper presented at the 24th HKSTS International Conference, 14-16 December, 2019, Hong Kong.
4. Varghese, V., Chikaraishi, M., Urata, J. (2019) Deep learning in transportation studies: A meta-analysis of methods, Paper presented at the 5th Conference of Transportation Research Group of India (CTRG-2019), 18-21 December, 2019, Bhopal, India.
5. 平井健二, 山下大輔, 吉野大介, 力石真 (2019) プローブパーソン調査を活用した災害時の行動モニタリングと交通サービス設計, 土木計画学研究・講演集, Vol. 60 (CD-ROM).
6. Watanabe, H., Chikaraishi, M., Maruyama, T. (2019) A flexible MDCEV Approach to Analyze Holiday Time-use Behavior for Leisure Activities, International Choice Modelling Conference 2019, 19-21 August, Kobe, Japan.
7. 力石真, 浦田淳司, 吉野大介, 藤原章正 (2019) 交通ネットワーク被災時の発生・集中・内々交通量及び旅行時間の変動特性, 土木学会論文集B1 (搭載決定)
8. Safitri, N.D., Santos, J.R., Safira, M., Varghese, V., Chikaraishi, M. (2019) Road Network Vulnerability: A Nationwide Analysis of 69 Cities from Japan, 2019 International Conference on Climate Change, Disaster Management and Environmental Sustainability, Kumamoto, September 19-21, 2019.
9. Santos, J.R., Safitri, N. D., Safira, M., Varghese, V., Chikaraishi, M. (2019) Road network vulnerability: A nationwide analysis of 69 cities from Japan, presented at JSCE conference, Toyama, November 30, 2019.
10. Chikaraishi, M., Fujiwara, A. (2020) Optimal design for pretest-posttest multiday panel experiments: An impact evaluation of owning new mobility vehicle, Presented at the 12th International Conference on Transport Survey Methods, May 31-June 5, Lisbon (accepted).
11. Santos, J.R., Safitri, N.D., Safira, M., Varghese, V., Chikaraishi, M. (2020) Road network vulnerability: A nationwide analysis of 69 cities from Japan, INSTR, Presented at the 8th International Conference on Transport Network Reliability, 24-26 June, Stockholm (accepted).

査読中

12. Chikaraishi, M., Garg, P., Varghese, V., Urata, J., Yoshizoe, K., Shiomi, Y., Watanabe, R.: Short-term traffic prediction under non-recurrent congestion: A machine learning approach for traffic management during disaster, Transport policy (2nd round review).
13. Varghese, V., Chikaraishi, M., Jana, A.: The Architecture of Complexity in ICT- Travel Relationships: A New Perspective Through the Review of Empirical Studies, Transportation Research Part C (3rd round review).
14. Varghese, V., Chikaraishi, M., Urata, J.: Deep Learning in Transport Studies: A Meta-Analysis on the Prediction Accuracy, Knowledge-based systems (1st round review)
15. Watanabe, H., Chikaraishi, M., Maruyama, T.: Intra- and inter-individual variations in holiday time-use considering workday impacts in two Japanese cities, Travel Behavior and Society (under revision for 2nd round review).

⑧研究成果の活用方策

(本研究から得られた研究成果について、実務への適用に向けた活用方法・手段・今後の展開等を記入。また、研究期間終了後における、研究の継続性や成果活用の展開等をどのように確保するのかについて記述。)

実務への適用に向けた活用方法・手段・今後の展開

- 広島県警と共同で信号制御実験を予定しており、構築した短期予測手法の実装可能性について引き続き検討する。
- 中国地方整備局「広島・呉・東広島都市圏災害時交通マネジメント検討会」や国際シンポジウムの開催等を通じて研究成果を適宜実務にフィードバックする。
- これまでに実施したPP-SP調査をベースに、交通需給マネジメントのプラットフォーム(アプリ)の基本設計について検討する。
- 研究成果を可能な限り学術論文としてまとめ、次世代型交通需給マネジメントの社会実装を後押しする。

研究期間終了後の研究の継続性や成果活用の展開

- 「科研費(学術変革領域研究)」への応募等を通じて更なる学術的知見の蓄積を進める。
- 本研究において構築した要素技術をベースに交通需給マネジメントアプリの開発を継続して行う。

⑨特記事項

(本研究から得られた知見、学内外等へのインパクト等、特記すべき事項があれば記入。また、研究の目的・目標からみた、研究成果の見通しや進捗の達成度についての自己評価も記入。)

中間評価結果(2019年3月受理)コメントへの対応

1. 既存の交通行動分析に関する理論と、AIに基づくデータ解析との、棲み分けまたは連動を念頭に置きつつ、検討を進めることが望ましい。
 - ✓ AIに基づくデータ解析が必ずしも交通理論と整合するわけではないこと、適合度のみで機械学習モデルの選択を行うと誤った判断をする可能性があることを示した、現在、引き続き、既存の交通理論と整合的になるように探索空間を限定した機械学習アルゴリズムの実装可能性等について検討を進めている。
2. 研究名にある「総合的」な交通需要マネジメント(あるいは、交通需給マネジメント)に向けて、それを意識するあまり「総花的」な研究にならないよう、また先端的な研究成果が得られるよう、留意いただきたい。
 - ✓ まずは実証的に研究が進められる範囲に限定してICTの枠組みを考えて研究を進めることにした。具体的には、(1) 交通マネジメントに必要な選好情報を即座かつ簡便に取得し(本年度実施)、(2) 必要に応じてレコメンデーションを発信できる(来年度実施予定)機能を有した交通マネジメント用アプリのプロトタイプ構築とその実験的導入を通じて、PP調査アプリを交通受給マネジメント用アプリに昇華する道筋を示したいと考えている。
3. 多様な交通サービス提供主体間の協調という目標に向けた、交通需要(需給)マネジメント手法の提案に期待する。
 - ✓ 供給制約を踏まえた上で需要側にレコメンデーションを発信する、公共交通機関へのフィーダーモードとして配車サービスを利用するようレコメンデーションを発信する、といった方法が社会的余剰の増大に資するかを検討する予定である。