

災害復旧期における 日常活動需要計算のための アクティビティシミュレータの構築

佐々木 泰¹・浦田 淳司²・井料 隆雅³

¹学生会員 神戸大学大学院 工学研究科市民工学専攻 (〒 657-8501 神戸市灘区六甲台町 1-1)
E-mail: 184t112t@stu.kobe-u.ac.jp

²正会員 東京大学大学院 工学系研究科社会基盤学専攻 (〒 113-8656 東京都文京区本郷 7-3-1)
E-mail: urata@bin.t.u-tokyo.ac.jp

³正会員 神戸大学大学院教授 工学研究科市民工学専攻 (〒 657-8501 神戸市灘区六甲台町 1-1)
E-mail: iryo@kobe-u.ac.jp

災害復旧期においては、被災者が物資調達など復旧期特有の行動をとる一方、付近の非被災者においても平時と異なる行動が発生する。非被災者の場合、基本的な行動パターンは変わらないと想定されるが、ネットワークへのダメージや需要変動による旅行時間変化の影響を受ける。復旧期の交通需要を予測するためには、被災者だけでなく非被災者の行動を再現するモデルが必要である。そこで本研究では、復旧期に行われる非被災者の日常的な活動を再現するアクティビティシミュレータを構築した。このシミュレータは大規模交通調査データを用いて個人の一日のスケジュールを作成するモデルである。提案モデルは災害復旧期に関わらず平時においても適用可能だが、特に復旧期に旅行時間が変動することによる活動への影響を再現することができる。また、実ネットワークへの適用を見据え、滞在人口を用いてシミュレーションパラメータのチューニングを行う。

Key Words: *Refuge management, Activity simulator, Traffic demand, Parameter tuning*

1. はじめに

近年、東日本大震災、熊本地震や西日本豪雨災害など、避難生活を伴う大規模な災害が各地で発生している。また、東南海地震や首都直下地震などの発生も想定されている。これらの災害では、災害の直後の避難・救急対応だけでなく、避難生活や復旧活動を円滑に進めるための支援やマネジメントが重要である¹⁾²⁾。過去の災害では、復旧期の交通渋滞が救援物資輸送や経済活動回復の遅滞を招くことが指摘されており、復旧期の交通需要を予測し、旅行時間低下を防ぐためのネットワーク計画の重要性は高い。例えば、熊本地震発災後には、道路の損傷による代替ルートの使用、住居・インフラ被害による必要物資の確保などの行動による渋滞が確認されている³⁾⁴⁾。また、災害復旧期には、被災者が物資調達など復旧期特有の行動をとる一方、付近の非被災者においても平時と異なる行動が発生する。非被災者の場合、基本的な行動パターンは変わらないと想定できるが、ネットワークへのダメージや需要変動による旅行時間変化の影響を受けよう。そのため、旅行時間変化の予測や頑健なネットワーク計画のためには復旧期の交通需要の予測が必要であり、その際には被災者ととも非被災者の行動を予測するモデルが必

要である⁵⁾。

本研究では、復旧期に行われる非被災者の日常的な活動を再現するアクティビティシミュレータ、AS-TRO(Activity Scheduler To Reproduce Observed behavioral data with trip-chain condition)を構築する。アクティビティシミュレータとは「すべての移動は活動の派生需要である」という考えのもと、個人・世帯の活動・移動パターンを予測し、再現するモデルである⁶⁾。代表的なモデルとしては、一日の行動パターンを確率的に選択するBowmanとBen-Akivaのモデル⁷⁾、PCATS⁸⁾などがある。これらは、個人の行動原理に基づいた個人ベースのシミュレーションを行うことで、マクロなモデルでは難しいイレギュラーな状況にも対応可能な柔軟なモデルである。本研究ではアクティビティシミュレータTASHA(Toronto Area Scheduling model for Household Agents)⁹⁾¹⁰⁾を基として構築する。TASHAは、平時を対象とする大規模交通調査で得た活動分布を用いて、個人の一日のスケジュールを作成するモデルである。パーソントリップデータに類する大規模交通調査で得た活動分布から活動の頻度・開始時刻などを生成した後、重複の無いよう調整を加えて一日のスケジュールとする。TASHAは調査データの活動分布を基にしたアクティビ

ティシミュレータであり、用いるパラメータは比較的少数のため、平時行動パターンを再現しやすい。また、移動時間を考慮したスケジュール重複を確認する工程があり、旅行時間の長期化によるトリップ取りやめが評価できる。この点で、旅行時間の増加により活動量が増える復旧期のアクティビティ再現に適したシミュレータである。一方で、TASHAの活動削除・追加の工程は、元の活動分布の維持を考慮せずに構築されている。本研究では、TASHAの平時活動データからサンプリングを行う構造はそのまま用い、スケジュール重複時の活動削除や空白スケジュールがある場合の活動追加を行う工程を新たに構築する。具体的には、スケジュールが重複した場合に、元の活動分布による条件付き確率を用いることで、活動を再生成するアルゴリズムを導入する。空白スケジュールがある場合には、活動を追加する場合と追加しない場合の元データにおける人数比を用いて活動追加を検討する。

また、実ネットワークへの適用を見据え、滞在人口分布を用いてシミュレータのパラメータチューニングを行う。交通手段選択や目的地選択に関するパラメータは平時と災害後で異なっている可能性があり、パラメータのチューニングが必要となる。チューニングには、災害復旧期にも観測が比較的容易である携帯GPSデータなどを集計して得られる各ゾーンでの滞在人口データ⁵⁾を用いる。災害後の滞在人口分布によるチューニングにより、シミュレーション精度を高める。ASTROが元とする大規模交通調査は10年に1度程度の頻度でしか行われておらず、リアルタイムに取得可能な滞在人口データによるパラメータ更新を行うことで、平時での適用可能性も広がる。なお、将来的には、本論文で構築した非被災者のシミュレータと、別途構築している被災者のシミュレータを組み合わせて滞在人口に対するチューニングを行うが、本論文ではASTROのみでチューニングを行う。パラメータチューニングの手法には進化的計算を用いる。進化的計算は生物の集団遺伝・進化の過程を模倣して最適化問題を解く手法であり、必ずしも最適解を得られるわけではない。しかし、構造が分からない問題、解の探索時間が膨大となる問題で、実用的な時間で相応の解を得ることができる。本研究では、その進化的計算の中でも代表的な遺伝的アルゴリズム (Genetic Algorithm: GA) と差分進化 (Differential Evolution: DE) を用いてチューニングを行う¹¹⁾¹²⁾¹³⁾。

本論文の構成は以下のとおりである。2.ではアクティビティシミュレータの内容を説明する。3.ではシミュレータで用いるパラメータのチューニング方法について述べる。4.ではシミュレータの性能評価、パラメータチューニング結果を示す。5.は本論文の結論である。

2. アクティビティシミュレータの構築

(1) シミュレータの概要

本シミュレータは大規模交通調査データから個人ごとのトリップデータを読み込み、それを基にした個人の活動・トリップスケジュールを作成する。中にはいくつかの操作可能なパラメータが設定されており、それらを変更することによりインプットデータとは異なる特徴を持つスケジュールを作成することが可能である。シミュレータは以下6つの流れで構成される。

1. 活動分布の作成
2. 活動の生成
3. 活動順序の調整
4. 目的地・交通手段選択
5. 再サンプリング
6. 追加サンプリング

まず、インプットデータとしてパーソントリップデータに類する大規模交通調査データを読み込み、1. 個人属性、活動に関する分布を作成する。作成した分布に基づき、2. 確率的に個人ごとの属性と活動を生成する。活動を生成し並び変えただけでは活動の順序が不自然になる場合があるため、3. 活動順序の調整を行う。次に、活動ごとに4. 目的地・手段選択を行い、出発地・到着地・交通手段を踏まえて旅行時間を算出する。ここで、算出した旅行時間を含めた活動・移動時間重複の有無を判定する。スケジュールの重複が生じた場合は、その重複を解消するため、5. 活動場所または活動開始時刻、活動時間の再サンプリングを行う。最後に、活動数の過小評価を防ぐため、活動・移動間の空き時間を踏まえ、6. 活動を追加するサンプリングを実行する。以上により、インプットデータの分布に従う個人ごとのスケジュールが生成する。

(2) 活動分布の作成・活動の生成

インプットデータであるパーソントリップデータは二つの目的で使用する。一つは個人の基本情報の作成、二つ目は活動の生成のためである。

一つ目の個人の基本情報として、個人属性分類、居住地、勤務地の分布を作成する。本研究では、個人属性は表-1の分類を用いる。なお、実地域を対象とする場合は、共通する活動分布の傾向を持つ個人属性分類を用いることが望ましい。居住地は個人属性ごとに分布を作成し、勤務地は個人属性と居住地ごとに分布を作成する。

活動の生成において使用する分布は活動数、開始時刻、活動時間の三つである。活動数分布は個人属性と活動目的別に作成し、開始時刻分布は個人属性と活動目的、活動数別に作成する。活動時間分布は個人属性

表-1 個人属性分類

	個人属性	年齢	性別
1	子供	20歳未満	—
2	成人男性	20歳以上 70歳未満	男性
3	成人女性	20歳以上 70歳未満	女性
4	高齢者	70歳以上	—

と活動目的、開始時刻別に作成する。ここで活動目的分類は下の5つを用いる。

1. 業務
2. 仕事・学校
3. 私事
4. 最終帰宅
5. 途中帰宅

活動順序の調整や再サンプリングで用いる活動優先度は上記の順とし、業務目的が最も優先度が高く、途中帰宅が最も優先度が低く、設定する。

作成した分布に応じて、一人ずつ個人の情報、活動を作成する。具体には、分布から個人属性をサンプリングし、個人属性ごとの分布から居住地、勤務地を作成し個人の情報とする。続いて個人属性ごとの分布から活動回数、開始時刻、活動時間を順に作成し一日の活動とする。

(3) 活動順序の調整

活動を生成し順に並べただけでは、活動の順序が不自然になる場合がある。そのスケジュールの矛盾を解消するため、活動順序の調整を行う。調整対象のスケジュールの矛盾は次とする。

1. 最終帰宅より後ろに他の活動が存在する。
2. 会社・学校が連続、または途中帰宅が連続する。
3. 先頭に途中帰宅が存在する。
4. 最終帰宅の直前に途中帰宅が存在する。

それぞれの矛盾に対して、基準となる活動を a 、活動 a と矛盾した活動を b とする。調整が採択された場合は活動 b の開始時刻・活動時間を変更する。活動順序の調整実施確率は、活動 a の活動開始時刻を t_{sa} 、活動 b の活動回数を n_b としたとき、

$$P_{done}(t_{sa}, n_b) = \frac{M^h(\{k_b + n_b\} \cap \{k_a + t_{sa}\})}{M^h(k_a + t_{sa})} \quad (1)$$

分母のうち k_b の活動回数が同じ
活動 a と開始時刻が同じ

h : 個人属性

t_{sz} : 活動 z の開始時刻

k_z : 活動 z の目的

n_z : 活動 z と同じ目的の活動数

$M^h(Z)$: 元データにおける個人属性 h の活動集合 Z を満たす人数

$\{k_z + t_{sz}\}$: 活動目的が k_z 、開始時刻が t_{sz} である活動集合（以降活動集合を条件の和で記述する）

で定義する。 P_{done} に従い、調整実施が採択をされた場合は、 $M^h(\{k_b + n_b\} \cap \{k_a + t_{sa}\})$ に該当する元データから一人の行動データをサンプルし、 k_b と同じ目的の開始時刻・活動時間を全て採用（交換）する。調整を棄却した場合は、活動順序の矛盾を解消するため、活動 b の削除や統合等を行う。具体の解消方法は表-2に示す。一連のスケジュール調整は、全ての矛盾がなくなるまで繰り返し行う。

棄却時の上記の矛盾解消方法を用いれば、簡易に活動順序の矛盾を解消することができる。しかし、この解消方法は活動 b を減らすのみの処理であるため、この方法のみでは活動数がインプットとなる活動データから大きく減少してしまう。そこで、調整実施確率 (1) として、活動 a の開始時刻及び活動 b と同じ目的の活動回数が等しい行動データの生成確率を用いる。これにより、 $\{k_b + n_b\} \cap \{k_a + t_{sa}\}$ を満たす活動 b を元のデータと同じ割合で生成できる。

(4) 目的地・交通手段選択

目的地・交通手段を決定し、各活動間の旅行時間を計算する。交通手段選択は旅行時間を効用とする多項ロジットモデルで記述し、各活動間で逐次実行する。確定効用は、簡易に、

$$V_{i \rightarrow j} = -\alpha_t \cdot c_{i \rightarrow j} \quad (2)$$

α_t : 交通手段選択における旅行時間パラメータ

$c_{i \rightarrow j}$: OD ペア ij 間の旅行時間

で表す。

目的地選択を行うのは私事、業務目的のみとし、途中帰宅、最終帰宅は居住地、仕事・学校は勤務地を活動場所として固定する。目的地選択では、旅行時間と目的地魅力度を効用とする。確定効用は

$$V_{i \rightarrow j} = -\beta_t \cdot c_{i \rightarrow j} + \beta_g \cdot G_j \quad (3)$$

β_t : 目的地選択における旅行時間パラメータ

β_g : 目的地選択における魅力度パラメータ

G_j : 目的地 j の魅力度

で表す。

(5) 再サンプリング

スケジュール調整後に行った目的地・交通手段の決定により、活動間の旅行時間が算出可能となる。その旅行時間を考慮すれば、活動・移動時間に重複が生じうる。活動・移動間に重複が生じた場合、優先度が低い活動の再サンプリングを検討する。再サンプリング対象は活動場所と開始時刻・活動時間であり、再サンプリン

表-2 スケジュール調整

	活動 a	活動 b	調整棄却時
1	最終帰宅	最終帰宅より後ろ	最終帰宅を活動 b の後ろへ 最終帰宅より活動優先度の活動は削除
2	連続する先頭	連続する先頭以外	活動 b を活動 a に統合
3	途中帰宅の次	先頭の途中帰宅	活動 b を削除
4	最終帰宅	途中帰宅	活動 b を削除

グが棄却された場合は、優先度が低い活動を削除する。

a) 活動場所の再サンプリング

活動場所を再サンプリングすることで旅行時間を変化させ、時間枠内に収まるようにする。ここで再サンプリングを行うのは、目的地選択によって活動場所を決定する活動目的「私事、業務」の二つである。再サンプリング実施確率は

$$P_{done}^d = \frac{N^h \left(\hat{X} \cap \{k + o + d + t_s(d)\} \right)}{N^h \left(X \cap \{k + o + d + t_s(d)\} \right)}$$

分母のうち時間枠内で到達可能

$$= \frac{\hat{X} = X \cap Y}{\text{目的} \cdot \text{開始時刻} \cdot \text{前後の活動場所が同じ}}$$

(4)

k : 活動目的

o : 前の活動場所

d : 次の活動場所

$t_s(d)$: 開始時刻

$N^h(Z)$: 元データにおける個人属性 h の活動集合 Z を満たす活動数

X : 元データにおける活動場所集合

Y : 時間枠内で到達可能な活動場所集合

で定義する。再サンプリングが採択された場合は、 $N^h \left(\hat{X} \cap \{k + o + d + t_s(d)\} \right)$ から活動場所を選択する。

活動場所の再サンプリングにあたり、再サンプリング実施確率として元の活動データの目的地分布の比率を用いている。これは、スケジュール調整と同様に、元データの再現性を高めるためである。重複がある場合は活動削除、またはすべての活動を時間枠内に収まる活動場所に変更と一方的な再サンプリングを行った場合、元データの活動場所の分布を再現できない。

b) 開始時刻・活動時間の再サンプリング

前述の活動場所の再サンプリング後も活動の重複が残る場合には、開始時刻・活動時間を再サンプリングし、時間枠内に収まるスケジュールへの変更を検討す

る。再サンプリング実施確率は

$$P_{done}^t = \frac{N^h \left(\hat{T}_s \cap \hat{T}_d \cap \{k + x\} \right)}{N^h \left(T_s \cap T_d \cap \{k + x\} \right)}$$

移動時間を考慮した範囲内の実施数
= 移動時間を考慮しない場合の実施数

$$t'_s + t'_d + t_t \leq \hat{T}_s, \hat{T}_s + \hat{T}_d \leq t''_s - t''_t$$

$$t'_s + t'_d \leq T_s, T_s + T_d \leq t''_s$$

(5)

x : 活動場所

t_d : 活動時間

t_t : 旅行時間

t' : 前の活動

t'' : 次の活動

T_s : 元データにおける開始時刻集合

T_d : 元データにおける活動時間集合

で定義する。再サンプリングが採択された場合は、移動時間を考慮した時間枠内で行われた元データの活動から開始時刻、活動時間を選択する。この開始時刻・活動時間の再サンプリングは活動の重複を解消する最後の調整である。

元データの再現性を高めるため、今までの工程と同様に一方的な活動削除や時間の変更は行わない。再サンプリング実施確率として、元データにおける目的・場所が同じ活動集合の移動時間を考慮した範囲での実施割合を用いる。これにより、移動時間を考慮した時間枠内に収まる活動へ変更するか、収まりきらず活動を削除するかを元データに従う確率で決定できる。

(6) 追加サンプリング

スケジュール調整と再サンプリングでは活動の維持または棄却を行っている。そのため、全体の活動数は減少してしまう。そこで、追加サンプリングとして、活動・移動の空き時間に活動を追加することを検

討する．追加サンプリング実施確率は

$$P_{add}(C_f, t_v) = \frac{\sum_{k \in K} M^h(C_f + a^k)}{M^h(C_f) + \sum_{k \in K} M^h(C_f + a^k)}$$

$$= \frac{\text{活動追加したスケジュールの観測数}}{\text{活動を追加しない} + \text{追加する}}$$

$$T_d(a^k) \leq t_v \quad (6)$$

C_f : 活動数の組み合わせ

t_v : 最大空き時間

a^k : 活動目的 k の追加アクティビティ候補

K : 活動目的集合

T_d : 活動時間

で定義する．追加サンプリングが採択された場合は $M^h(C_f + a^k)$ の比率

$$Q(k_0, t_v) = \frac{M^h(C_f + a^{k_0})}{\sum_{k \in K} M^h(C_f + a^k)} \quad (7)$$

$$T_d(a^k) \leq t_v$$

に合わせて，追加する活動の目的 k_0 を選択する．ただし，節 (3) のスケジュールの矛盾を生じる活動目的が選択された場合は，追加サンプリングを棄却する．

目的地選択・交通手段選択を行い活動場所と旅行時間を決定し，最後に旅行時間を考慮した空き時間枠内に収まる開始時刻・活動時間をサンプリングする．時間枠内に収まる開始時刻 t_s ・活動時間 t_d の選択確率は，元データから作成した同時確率である

$$Q(t_s, t_d) = \frac{N^h(t_s + f)}{N^h(T_s \cap \{f\})} \times \frac{N^h(t_d + t_s)}{N^h(T_d \cap \{t_s\})} \quad (8)$$

$$t'_s + t'_d + t_t \leq T_s \leq t''_s - t''_t$$

$$0 \leq T_d \leq t''_s - t''_t - t_s$$

f : 活動回数

を用いる．時間枠内に収まるような元データが存在しない場合は，追加サンプリングを棄却する．最大空き時間に対する追加の試行が棄却されるまで，追加サンプリングを繰り返し行う．

追加サンプリング実施確率は，活動を追加した場合の活動組み合わせと追加しない場合の組み合わせの比率により定式化した．これにより，元データの活動組み合わせに準ずる活動の追加調整を可能とした．

3. パラメータチューニング

(1) パラメータの設定

各ゾーンの滞在人口が観測されている場合，シミュレーションの再現性を担保するため滞在人口によるパラメータチューニングを行う．本節では，チューニングすべきパラメータの検討を行う．まず，候補となるのは目的地選択のパラメータである．具体には式 (3) の β_t , β_g の二つが挙げられる．これらのパラメータは交通需

表-3 パラメータ探索範囲

β_t	0.0~2.0
β_g	0.0~2.0
α_t	0.0~2.0
乱数シード	0~100

要を予測するうえで重要な目的地選択を支配するパラメータであり，災害復旧期に適したパラメータへ再設定する必要がある．次の候補としては，交通手段選択のパラメータ (式 (2) の α_t) が考えられる．このパラメータも，交通手段の決定という交通行動に大きな影響を与えるパラメータであるため，チューニングが必要である．

本研究ではパラメータチューニングを次の方法で検証する．まず，真の行動パラメータを設定した上で，シミュレーションを実行し，滞在人口分布を作成する．次に，作成した滞在人口分布をインプットとし，上記の行動パラメータを未知として，パラメータチューニングを試みる．しかしながら，シミュレーションでの作成には確率的選択が多数含まれており，疑似乱数の設定による滞在人口の変動は大きい．また，計算コストの問題で，パラメータチューニングで用いる滞在人口分布のセット数も十分ではなく，疑似乱数の影響は無視できない．つまり，シミュレーションのたびに乱数のシードが変動しては，パラメータが同一であったとしても滞在人口が一定とならず，チューニングの収束が著しく妨げられる．この課題に対処するため，以下二つの方法でパラメータチューニングを試みる．

1. 乱数のシードをハイパーパラメータとしてチューニングし，目的関数は真値として作成したあるパラメータでの滞在人口とシミュレーション結果の滞在人口の差の絶対値の和とする．
2. 乱数のシードは固定せず，目的関数をシミュレーション 100 回分の滞在人口と真値との差の絶対値の和とする．

方法 1 は，乱数のシードをハイパーパラメータとすることで，ある特定の乱数列に対するチューニング結果となるため，チューニング後にシミュレーションを行う場合の乱数シードも固定しなければならないという問題がある．方法 2 は，シミュレーションを大量に行うことで，乱数による変動の影響を抑えることを目的としているが，計算コストがかかる．

それぞれのパラメータの探索範囲を表-3 に示す．以上の設定により，シミュレーションパラメータのチューニングを行う．

(2) 遺伝的アルゴリズム (GA)

GA は自然淘汰の仕組みを最適化問題に応用したアルゴリズムである。流れを以下に簡単に示す¹⁴⁾¹⁵⁾。

1. ランダムに初期の個体群を生成，適応度（目的関数）の計算。
2. 適応度をもとに親となる個体を選択。
3. 親個体を交叉し，子個体を生成。
4. ある確率で突然変異（親が持たない遺伝子の発生）を起こす。
5. 子世代を親世代に移行し，終了条件を満たすまで 2 から 4 を繰り返す。

本研究でおこなう最適化対象は主に連続値であるため，実数値遺伝的アルゴリズム (Real-coded Genetic Algorithms: RCGA) を使用する。RCGA は個体の遺伝子表現として，2 値表現ではなく実数値ベクトルを用い，変数の連続性を考慮した交叉手法を導入した GA である¹¹⁾¹⁶⁾。本論文では交叉手法として，Eshelman によって考案されたブレンド交叉 (Blend Crossover: BLX- α) を用いる。また，突然変異には実行可能領域内で一様乱数を発生させる一様突然変異を用いる。終了条件は世代数が上限に達した場合とする。

(3) 差分進化 (DE)

DE は Storn と Price¹³⁾ によって提案された，GA よりも新しい進化的計算の一種である。他の進化的計算と同様に解集団に対する確率的な多点探索を行うが，突然変異におけるステップ幅を探索点の収束に比例して決めるためステップ幅の制御が不要である。また，非線形問題，微分不可能な問題，非凸問題，多峰性問題など様々な最適化問題に適応されており，これらの問題に対して高速で頑健なアルゴリズムであることが示されてきている。DE のアルゴリズムは改良手法を含め様々な手法が提案されているが，代表的な DE/rand/1/exp アルゴリズムを以下に示す¹¹⁾。

1. 各ベクトル（個体） $X_i (i = 0, 1, \dots, n - 1)$ の初期化と適応度（目的関数値）の計算。
2. ランダムに目標ベクトル X_t を選択。
3. ランダムに 3 つのベクトル X_a, X_b, X_c を選択（ただし X_t, X_a, X_b, X_c は互いに異なる）。
4. 突然変異は

$$V = X_a + F \times (X_b - X_c) \quad (9)$$

を用いて行う。 F は突然変異率で正の定数とする。

5. X_t と V を交叉率 CR で交叉し，新しいベクトル X_s を生成する。 CR は正の定数。
6. X_t と X_s の目的関数値を比較して，目的関数値の高いベクトルを次世代に残す。
7. 終了条件を満たすまで 2 から 6 を繰り返す。

本論文では，アルゴリズムとして DE/rand/1/exp を使用

表-4 計算環境

CPU	Xeon(R) E5-2630 V3@2.40GHz
OS	Ubuntu 14.04.5
メモリ	64GB
コンパイラ	g++ ver.4.8.4
オプション	-O3 -std=c++11

した。終了条件は世代数が上限に達した場合と，全個体のパラメータが収束した場合とする。

4. 数値計算

本章では PT データを参考に作成した 1000 人分のサンプルデータを用いたシミュレーション結果を示す。計算の対象地域として，5×5 の格子状のゾーン群（計 25 ゾーン）を用いる。シミュレータ本体は C++ で構築し，パラメータチューニングは Python で行った。パラメータチューニング用のライブラリとして GA では DEAP，DE は SciPy を利用した。計算環境は表-4 のとおりである。

(1) シミュレータの性能検証

a) 基本性能検証

1000 人分のサンプルデータを入力として，シミュレーションを 1000 回行った。インプットデータとシミュレーション結果 1000 回分の比較を表-5 に示す。追加サンプリングを行った場合の総トリップ数は，相対誤差-2.14% と精度よく再現できている。対して，追加サンプリングを行わなかった場合は相対誤差-17.4% と過小評価である。ここから追加サンプリングを行ったことによりトリップ過少が改善したことが確認できる。しかし，追加サンプリングを行った場合でも総活動時間と総旅行時間は過小評価となっており，それぞれの改善が望まれる。総活動時間の減少は，活動が重複した際の再サンプリングにおいて活動時間が短い活動が選ばれやすいことが原因であろう。アクティビティを延長する操作を加えることで，活動時間の改善を行うことができるだろう。総旅行時間は総活動時間ほどではないが，過小評価となっている。目的地の再サンプリングによって，旅行時間の短い近くのゾーンが選ばれやすくなっているためと考えられる。

b) 時間帯・目的別トリップ数

インプットデータとシミュレーション結果 1000 回分の時間帯・目的別トリップ数の比較を表-6 に示す。シミュレーション結果のトリップ数は 1000 回の試行の平均値を用いている。

目的別にみると，私事，仕事・学校のトリップ数は精

表-5 基本数値の比較

	入力	追加サンプリングあり		追加サンプリングなし	
		平均 (標準偏差)	相対誤差 %	平均 (標準偏差)	相対誤差 %
人数	1000	1000		1000	
総トリップ数	2984.0	2919.9 (±38.6)	-2.15	2463.7 (±27.3)	-17.4
総活動時間 (時間)	5055.0	4431.4 (±99.1)	-12.33	3787.0 (±95.6)	-25.1
総旅行時間 (時間)	1649.5	1519.0 (±28.5)	-7.91	1321.3 (±24.4)	-19.9
計算時間			156 s		109 s

表-6 時間帯・目的別トリップ数の比較

活動目的		am	mid	pm	night	Total
		6:00am-	9:00am-	3:00pm-	7:00pm-	
業務	output trips	123.3	175.0	28.9	149.0	476.2
	input trips	111.0	127.0	22.0	113.0	373.0
	output ± trips	12.3	48.0	6.9	36.0	103.2
	output ± %	11.1	37.8	31.2	31.9	27.7
仕事・学校	output trips	66.8	105.8	8.1	337.4	518.1
	input trips	83.0	97.0	12.0	355.0	547.0
	output ± trips	-16.2	8.8	-3.9	-17.6	-28.9
	output ± %	-19.5	9.1	-32.7	-5.0	-5.3
私事	output trips	156.2	512.5	168.4	32.7	869.8
	input trips	141.0	507.0	174.0	22.0	844.0
	output ± trips	15.2	5.5	-5.6	10.7	25.8
	output ± %	10.8	1.1	-3.2	48.7	3.1
最終帰宅	output trips	0.8	228.5	646.4	123.3	998.9
	input trips	5.0	379.0	547.0	69.0	1000.0
	output ± trips	-4.2	-150.5	99.4	54.3	-1.1
	output ± %	-83.9	-39.7	18.2	78.7	-0.1
途中帰宅	output trips	10.3	44.3	2.3	0.0	56.9
	input trips	36.0	159.0	25.0	0.0	220.0
	output ± trips	-25.7	-114.7	-22.7	0.0	-163.1
	input ± %	-71.4	-72.1	-90.8	0.0	-74.1
Total	output trips	357.4	1066.1	854.0	642.4	2919.9
	input trips	376.0	1269.0	780.0	559.0	2984.0
	output ± trips	-18.6	-202.9	74.0	83.4	-64.1
	output ± %	-5.0	-16.0	9.5	14.9	-2.2

度良く計算できているが、業務は過大評価、途中帰宅は過小評価となっている。これは活動優先度の影響であると考えられる。活動優先度が高い業務は再サンプリング等で活動が取りやめになることが少なく、反対に活動優先度が低い途中帰宅は活動の取りやめが起りやすい。改善策としては、活動優先度の設定を確率的に変更することが考えられる。

時間帯別でみると、日中が-16.0%の過小評価となっている。これはこの時間帯の途中帰宅が-72.1%と非常に小さくなっていることの影響である。途中帰宅は(業務と比べ)活動時間が短い場合が多い。日中における途中帰宅活動が適切にスケジュールできれば、トリップは増加すると考える。反対に、夜間は14.9%の過大評価となっているが、こちらはトリップが密集した昼間




図-1 旅行時間に対するトリップ数変化

のトリップが再サンプリングによって夜間にはじき出されたためと推測できる。時間帯別の活動数の精度を上げるためにも、まずは目的別の活動数の改善が必要である。

c) 旅行時間に対する感度

本研究では、災害復旧期での適用を見据え、旅行時間変化によるトリップ数の変動を評価できるシミュレータの構築を目指している。本節では旅行時間の変更によるトリップ数の変化を検証する。本シミュレータは交通流シミュレータとの統合により自動車の旅行時間を受け取ることを想定しており、災害復旧期の自動車の旅行時間変化を考慮できる。本節では車のみ旅行時間を変更する場合、全交通手段を変更する場合の2通りを計算する。また交通手段選択について、2.(4)に示した旅行時間の効用で選択する場合と、距離帯別交通手段分担率を用いて交通手段選択を行う場合の2通りを計算する。以上の4通りにおけるトリップ数の変動を図-1に示す。縦軸はトリップ数、横軸は旅行時間にかかる倍率である。

車のみ旅行時間を変更した場合は、トリップ数の変動がほぼ無い。これは、旅行時間が増えた自動車を交通手段として選択せず、トリップ減少への影響が抑えられたためと考える。対して、車のみ旅行時間を変更した場合でも、交通手段選択が距離帯別であればトリップ数は減少している。全ての交通手段の旅行時間を変更した場合は、交通手段選択の方法に関わらずトリップ数は減少する。以上より、構築したシミュレータは旅行時間の増加に感度をもつことを確認できた。

(2) パラメータチューニング結果

a) 方法 1

疑似乱数のシードをハイパーパラメータとして、合計4つのパラメータに対してチューニングを行う。乱

数シードを変えながら10個の真値滞在人口を作成し、それぞれに対してチューニングした結果を表-7に示す。表中の総計算時間は10回のパラメータチューニングの合計計算時間である。RCGAについては、最大でも推定成功数が3回であり、10000世代チューニングを行ってもよい結果が得られなかった。より世代を重ねるとチューニングできる可能性はあるが、計算時間が多大になってしまうため、現実的ではない。同程度の世代数でよい結果を得るためには、アルゴリズムを見直す必要がある。なお、今回の計算では、実数値に用いる最もシンプルな交叉手法であるブレンド交叉を用い、突然変異は一様乱数で発生させる方法を用いている。

DEでは、目的地選択のパラメータは10回の試行の内それぞれ7回と10回推定が成功した。対して交通手段選択は5回であり、推定の精度は低下した。これは滞在人口が交通手段別ではないため、滞在人口から読み取ることのできる交通手段の情報が少ないことが原因であると考えられる。チューニングするパラメータを選定する際には、滞在人口への感度を考慮に入れる必要がある。

b) 方法 2

乱数のシードは固定せず、目的関数をシミュレーション滞在人口100回分の差の絶対値の和として行ったチューニング結果を表-8に示す。方法2は方法1でうまくチューニングできたDEのみ行ったが、方法1ほどのチューニング精度は得られなかった。また、評価関数が方法1よりも100倍の計算コストがかかるため、計算時間が非常に長くなった。局所解に落ちていないか、内部で使用しているアルゴリズムの種類が適切であるかなど検討を行い、更なる精度向上を目指したい。

5. おわりに

本論文では、災害復旧期の非被災者の行動を再現するアクティビティシミュレータを構築し、パラメータのチューニング方法を検討した。TASHAのアルゴリズムを改良することで、元の活動分布を歪めることなくスケジュールを生成する方法を考案した。再サンプリングでは、一方的な活動削除や活動の変更を行うことなく、元データに従う再サンプリング実行確率を計算することで、元データの分布に沿ったスケジュール調整を行うようにした。また、追加サンプリングについても、元データの活動組み合わせに従い確率的なサンプリングを行うようにした。シミュレータ全体で一貫して元データの分布を崩すことなく活動を生成することができたと考える。数値計算結果については、インプットデータに対するトリップ数の再現性を確認し、旅行時間に対するトリップ数の変動を再現できた。旅行時

表-7 パラメータチューニング結果 1

	RCGA (上限 10000 世代)				DE (上限 1000 世代)			
	β_t	β_g	α_t	乱数シード	β_t	β_g	α_t	乱数シード
真値	0.0500	1.0000	0.1000	0 から連番	0.0500	1.0000	0.1000	0 から連番
0	0.1505	1.7774	0.3456	47	0.0499	1.0000	0.1041	0
1	0.0502	1.0140	0.1855	8	0.0500	0.9763	1.4313	1
2	0.0337	1.0806	0.3070	52	0.0567	1.0431	0.1029	2
3	0.0479	1.0289	0.0550	31	0.0500	1.0001	0.0998	3
4	0.0859	1.2635	0.3106	47	0.0499	0.9932	0.0863	4
5	0.1736	1.6502	1.1341	84	0.0689	1.0946	0.3654	5
6	0.1238	1.5461	0.6249	53	0.0087	1.0613	0.6651	6
7	0.0850	1.2658	1.3529	36	0.0494	0.9947	0.0900	7
8	0.0731	1.1023	0.1907	40	0.0501	0.9866	0.1019	8
9	0.1439	1.6147	0.1783	72	0.0498	0.9988	0.1008	9
相対誤差が 10%以下	2 回	3 回	0 回	0 回	7 回	10 回	5 回	10 回
総計算時間	498min				178min			

表-8 パラメータチューニング結果 2

	DE (上限 1000 世代)		
	β_t	β_g	α_t
真値	0.0500	1.0000	0.1000
0	0.0480	0.9406	0.7574
1	0.0197	0.9591	0.0094
2	0.0682	1.1459	1.7099
3	0.0494	1.0196	0.0112
4	0.0224	0.9314	0.9764
5	0.0018	0.9926	1.5031
6	0.0606	1.0695	1.6035
7	0.0745	1.1551	0.3992
8	0.0280	0.9951	0.5044
9	0.0086	1.0345	1.0772
相対誤差が 10%以下	2 回	8 回	0 回
総計算時間	801min		

間に対する感度を確認できたことから、災害復旧期の旅行時間増加によるトリップ取りやめを評価できるシミュレータを構築できたと考える。チューニングは乱数シードをハイパーパラメータとした場合の DE において精度良く推定できた。ゾーン別滞在人口データを用いて、災害復旧期などの状況変化を受けてもシミュレータの再現性を担保する方法を示した。

今後の課題を述べる。一つ目は、目的別のトリップ数の改善である。優先度が高い活動のトリップ数が過大になる現象が確認されたので、優先度の設定を見直す必要がある。今回は優先度を確定的に与えたが、確

率的な優先度を用いることが解決策として考えられる。二つ目はパラメータチューニングの改善である。乱数のシードもチューニングする方法は、特定の乱数列に対して他のパラメータをチューニングするというものである。そのパラメータを使って別のシミュレーションを行う場合は乱数列の扱いに困る。方法2のように乱数シードを固定せずチューニングを行うのが理想的ではあるが、現状ではチューニングの精度は悪く、より良い手法の検討が必要である。また、いずれの方法でも交通手段選択のパラメータについてはチューニングが不十分であったが、これは滞在人口の交通手段選択パラメータに対する感度が低いことも影響していると考えられる。チューニング可能性と必要性を考慮し、再度パラメータを選定したい。最後は、実データへの適用である。本論文では、終始サンプルデータを使った検証を行ったが、実際のネットワークと PT データはサンプルとは異なる特性を持っており、実データを使って同様の検証を行う必要がある。特にパラメータチューニングを実行するためには高速で省メモリなプログラムが必要であり、現状では実データで実行できる水準に達していないため、より効率的なコードへの書き換えも行いたい。

謝辞: 本研究は、「ポスト「京」で重点的に取り組むべき社会的・科学的課題に関するアプリケーション開発・研究開発(文部科学省)」の重点課題(3)「地震・津波による複合災害の統合予測システムの構築」のサブ課題 B「統合的予測のための社会科学シミュレーション

の開発」の一環として実施された。

参考文献

- 1) 力石真: 平成 30 年 7 月豪雨に学ぶ交通システムのリスク・ガバナンス, 交通工学, Vol.54, No.3, 2019.
- 2) 力石真, 浦田淳司, 吉野大介, 藤原章正: 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(平成 30 年西日本豪雨災害特別企画),(登載決定), 2019.
- 3) 山口裕通, 奥村誠, 金田穂高, 土生恭祐: 携帯電話 GPS 情報から分かる熊本地震による行動パターンの被災・回復過程, 土木学会論文集 D3(土木計画学), Vol.73, No.5, pp.L105-L117, 2017.
- 4) 桑原雅夫, 原祐輔, 三谷卓摩, 川崎洋輔, 竹之内篤, 井料隆雅, 浦田淳司: 熊本地震における都市内交通, 避難の実態と課題, 第 54 回土木計画学研究発表会・講演集 (CD-ROM), 2016.
- 5) Urata, J., Sasaki, Y., and Iryo, T.: Spatio-temporal analysis for understanding the traffic demand after the 2016 kumamoto earthquake using mobile usage data, *21st International Conference on Intelligent Transportation Systems (ITSC)*, pp. 2496-2503, 2018.
- 6) 東京大学羽藤研究室: ネットワーク行動学 -都市と移動- 第 4 章 移動空間分析, <http://bin.t.u-tokyo.ac.jp/kaken/data/4-20140926.pdf>, 2018 年 7 月閲覧.
- 7) Bowman, J. L. and Ben-Akiva, M. E.: Activity-based disaggregate travel demand model system with activity schedules, *Transportation research part a: policy and practice*, Vol.35, No.1, pp.1-28, 2001.
- 8) 藤井聡, 大塚祐一郎, 北村隆一, 門間俊幸: 時間的空間的制約を考慮した生活行動軌跡を再現するための行動シミュレーションの構築, 土木計画学研究・論文集, Vol.14, pp.643-652, 1997.
- 9) Miller, E. J. and Roorda, M. J.: Prototype model of household activity-travel scheduling, *Transportation Research Record*, Vol.1831, No.1, pp.114-121, 2003.
- 10) Roorda, M. J., Miller, E. J., and Habib, K. M.: Validation of tasha: A 24-h activity scheduling microsimulation model, *Transportation Research Part A: Policy and Practice*, Vol.42, No.2, pp.360-375, 2008.
- 11) 伊藤聡, 田中雅博: 関数値最適化のための particle swarm optimization, differential evolution, 実数値遺伝的アルゴリズムの探索性能に関する検討, 甲南大学紀要. 理工学編, Vol.52, No.1, pp.125-135, 2005.
- 12) 久保幹雄, J.P. ペドロソ: メタヒューリスティクスの数理, 共立出版, 2009 年 5 月 10 日発行.
- 13) Storn, R. and Price, K.: Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces, *Journal of global optimization*, Vol.11, No.4, pp.341-359, 1997.
- 14) 大谷紀子: 進化計算アルゴリズム入門 生物の行動科学から導く最適解, オーム社, 2018 年 6 月 25 日発行.
- 15) 知的システムデザイン研究室 GA グループ: 卒論・修論作成のための基礎シリーズ 遺伝的アルゴリズム, <http://www.is.doshisha.ac.jp/text/ga20090504.pdf>, 2019 年 8 月閲覧.
- 16) 小野功, 山村雅幸, 喜多一: 実数値 GA とその応用, 人工知能学会誌, Vol.15, No.2, pp.259-266, 2000.

(2019. 10. 4 受付)

Traffic demand simulator for daily activities under disaster restoration period

Yasushi SASAKI, Junji URATA and Takamasa IRYO