

ライドシェアサービス解析のための分布探索手法

大滝 啓介†

† 株式会社豊田中央研究所

E-mail: †otaki@mosk.tytlabs.co.jp

あらまし モビリティサービスにおいてライドシェアによる車両資源の共有は重要である。その中でも移動リクエストの共有可能性 (shareability) は、オンデマンド交通などの研究において重要な概念として研究されてきた。共有可能性の解析を通じて、与えられた道路ネットワークとリクエストの集合に対して、迂回距離や共有価値など、シェアリング自体を数値的に評価することができる。しかしながら既存の技術は「求められる指標を達成するにはどのようなサービス状況であれば良いか」などの逆解析について検討されておらず、現実のサービス設計場面に適用するには課題がある。本稿ではリクエストの集合が G 上の離散分布から生成されると見なし、様々な分布を探索しながら逆解析を行うアプローチを提案する。また OpenStreetMap から抽出した実際の道路ネットワーク構造とランダムデータを用いた実験により、提案手法の評価と議論を行った結果を報告する。

キーワード ライドシェア, 共有可能性, 道路ネットワーク

1 はじめに

1.1 背景

モビリティサービスは、Mobility as a Service (MaaS) などのキーワードや、自動運転車両などの技術進歩に伴って注目を集めている [5]。すべての人に移動の自由を提供し、サービスやモノのライフサイクルを持続可能にしていくためには、CASE¹ と呼ばれる技術群に基づく効率的な車両運用が必要である。高効率な車両運用を行うためには、1 車両あたりがサービスを提供する人数を増やすことは重要であり、車両の共有 (Shared) やシェアリングサービスは重要なコンセプトである。つまり個人が自車で移動する場合と比較して、車両の共有によって渋滞や環境汚染の緩和へ貢献することが期待されている [4]。

Uber や Lyft をはじめとするモビリティサービス提供者は、Web やスマートフォンアプリなどを通じて顧客の移動需要 (リクエストと呼ぶ) を受け取りプールする。一定期間プールされたリクエストの集合と、サービスが運用する車両同士をマッチングした上で通知し、サービスを提供する。このマッチング処理を時間に沿って繰り返し行うことで、1 日のサービス提供の最適化を目指す。上記の問題設定は一般的に *Ride-Pool Matching Problem (RPM)* と呼ばれ、注目を集めている [1, 2, 7, 11]。

ある地域に実装されるオンデマンド交通サービスでは、それぞれのサービスが各々の目的に沿って運用される。そのため RPM を解く場合にも様々な目的関数が考えられる。運営側に着目すれば、車両の運用コストを最小化する問題や、顧客から得られる報酬の最大化問題となる。利用者側に着目すれば、待ち時間の最小化問題や、支払う費用の最小化問題となる。また間接的な目標として、ライドシェア率を向上させることや、ドライバーの事業体間の公平性を考慮した目的関数を設定するな

ど、様々なアプローチが考えられる。

RPM 問題をはじめとして、これまでに研究されているシェアリングサービスに関する計算技術は、順方向の解析技術である。つまり、ある地域の情報やリクエストの情報を入力とし、最適化問題を解くことで、最適化された運用スケジュールや得られる報酬、サービス提供数などを見積もることができる。一方で現実のサービス運営を想定すると、最適化するだけでなく、所望の結果 (例えば期待される報酬や利用者数) が得られる地域を選定するサービス箇所選定時などに、シェアリングサービス自体の逆解析が必要になる場面が多い。しかしながらシェアリングサービスの逆方向解析に関する統一的な方法論や、数理的な解釈手法は少なく、研究の発展が望まれる分野である。既存研究としてはサービスを評価するネットワークのトポロジーに注目した平均的な挙動解析 [8, 12] がされているが、需要の分布に注目した手法は数が限られている。

1.2 本稿の目的と内容

本研究の目的は、シェアリングサービスに関する研究において用いられる概念である **リクエストの共有可能性 (shareability)** に着目し [10]、モビリティサービスの評価や転移・逆解析に関する手法構築と議論を行うことである。シェアリングサービスにおける共有可能性とは、移動リクエスト同士を同じ車両で対応可能かどうかを評価する枠組みである。これらの技術を用いることで、ライドシェアサービスの平均的な挙動について議論することができる [6, 10]。

既存の手法 [6] では、ある対象とする地域とその上のランダムな移動リクエストに対して、シェアリングが行われうる確率や、移動距離あたりの期待価値を議論する手法である。図 1 を用いて考え方を説明する。注目している 2 人の顧客がリクエストを提示しているとき、この 2 人に対して配車を行うとする。今、2 人の移動に注目した場合に、考えられる車両の配車と移動のパターンは図 1 に示す (a)(b)(c) の 3 つが考えられる。

1 : Connected, Autonomous(/Automated), Shared(&Service), Electric の頭文字を意味するキーワード




図 1: 2 者の移動に関する 3 つのケース (Δ が乗車位置, ∇ が降車位置を表す) について [6] を元に作成した例題の図

- (a) 2 人共にライドシェアをする必要がなく, 単独で移動する (緑・橙ともに最短経路で移動する)
- (b) 1 車両を 2 人に配車し, 2 人は乗り合いして移動する. また 2 人が移動する経路は, 2 人の最短経路からの迂回が発生しない (橙の最短経路で緑が乗り込む)
- (c) 1 車両を 2 人に配車し, 2 人は乗り合いして移動する. 1 人以上の顧客に迂回が発生して, 最短経路より長い距離を移動する (緑は橙を下ろすために迂回する)

図 1 は位置関係に応じて車両共有の挙動が変化する例である. また [10] では時間や待ち時間も考慮して共有可能性を評価している. 共有可能性を評価することで 2 者間の「迂回距離」や「共有による価値」を数値として取得できるため, ライドシェアサービスの提供者はそれらの最小化・最大化に関する最適化問題を解くことで, 意思決定が可能となる.

本稿では図 1 と同様に, 2 者の共有状況を対象とする. たくさんの顧客の中から 2 者を選ぶ操作を繰り返すマッチングベースの RPM において, 共有可能性解析によって評価されるライドシェア確率などを対象に, サービスの挙動と逆解析を行う枠組みを構築する. 本稿の提案手法は以下のようなものである.

- 顧客の乗降車位置 (Δ/∇) を生成するために, 対象地域の道路ネットワークと頂点上の確率分布を用いる
- 図 1 の (a)(b)(c) を評価するシミュレータを実装し, 2 者がライドシェアする際の評価値を計算する
- サービスの状況を探るために様々な分布を探査し, 所望のサービス目標値を返すようなサービスの状況を探査して提示し, ライドシェアサービスの挙動を観察する

提案手法に基づくライドシェアサービスの逆解析アプローチについて, 実際の道路ネットワークとネットワーク上に生成したランダム人工リクエストを用いて確認し, 議論を行う.

2 準備

2.1 道路ネットワーク

対象地域のネットワーク構造を無向グラフ $G = (V, E, w)$ で表す. ここで V は頂点集合, $E \subseteq \{\{u, v\} \mid \{u, v\} \subseteq V^2, u \neq v\}$ を辺集合, $w : E \rightarrow \mathbb{R}$ は辺 $\{u, v\}$ の重み $w(\{u, v\})$ (単に $w(u, v)$ や $w_{u,v}$ と表す) を定義する. 2 頂点 u, v の間の最短経路距離を $d_{u,v}$ で表す. つまり $u \in V$ から $v \in V$ に移動する際に用いる最短経路が $\langle v_0, v_1, \dots, v_k \rangle, v_0 = u, v_k = v$ であるとき, $d_{u,v} = \sum_{i=0}^{k-1} w_{v_i, v_{i+1}}$ である.

2.2 ライドシェアの共有可能性解析

はじめにライドシェアの解析技術 [6] を説明する. 対象のネットワーク G 上のリクエスト r_i は頂点对 $(p_i, d_i) \in V \times V$ で表し, p_i は乗車位置 (Δ), d_i は降車位置 (∇) に対応するとする. ライドシェアにおける共有可能性解析とは, リクエストの集合 $\mathcal{R} = \{i = (p_i, d_i) \mid p_i \in V, d_i \in V \setminus \{p_i\}\}$ が与えられた際に, どのような配車方法や経路を利用するか, またその結果どのようなサービス成果が得られるのかを考察するための技術である.

a) 単独で移動する場合

2 者のリクエスト $i = (p_i, d_i)$ と $j = (p_j, d_j)$ が所与のとき, ライドシェアを行わない場合には, i と j に対してそれぞれ 1 台の車両を用意し, 総移動距離は $d_{p_i, d_i} + d_{p_j, d_j}$ となる.

b) 2 者が共に乗車する箇所がある場合

2 者のリクエスト i, j を 2 台ではなく 1 台の車両で対応する²ために, 以下の 4 パターンの移動を考える.

- (1) $(ijij)$ i が乗車 $\rightarrow j$ が乗車 $\Rightarrow i$ が降車 $\rightarrow j$ が降車
- (2) $(ijji)$ i が乗車 $\rightarrow j$ が乗車 $\Rightarrow j$ が降車 $\rightarrow i$ が降車
- (3) $(jiji)$ j が乗車 $\rightarrow i$ が乗車 $\Rightarrow j$ が降車 $\rightarrow i$ が降車
- (4) $(jiij)$ j が乗車 $\rightarrow i$ が乗車 $\Rightarrow i$ が降車 $\rightarrow j$ が降車

上記のパターンのうち, \rightarrow は単独で移動している箇所, \Rightarrow はライドシェアが発生している箇所を表す. パターンの 3 と 4 は, それぞれパターンの 1 と 2 と同種で先に乗車する顧客が異なる. パターンの集合を $\Pi = \{1, 2, 3, 4\}$ で表す.

以下ではパターン 1 ($ijij$) を用いて説明する. 以降では個人の最短経路を $c_u(i) := d_{p_i, d_i}$ で表す. パターン 1 での総移動距離は $c(i, j; 1) := d_{p_i, p_j} + d_{p_j, d_i} + d_{d_i, d_j}$ である. 1 はパターン 1 を意味する. 2 者 i と j は, それぞれの最短経路が d_{p_i, d_i} と d_{p_j, d_j} なため, $p_i \rightarrow p_j \Rightarrow d_i \rightarrow d_j$ の移動順において, それぞれ $d_{p_i, p_j} + d_{p_j, d_i} - d_{p_i, d_i}$ と $d_{p_j, d_i} + d_{d_i, d_j} - d_{p_j, d_j}$ の移動量がライドシェアによって生じる迂回距離である. 迂回距離の和を $r(i, j; 1) := d_{p_i, p_j} + d_{p_j, d_i} - d_{p_i, d_i} + d_{p_j, d_i} + d_{d_i, d_j} - d_{p_j, d_j}$ で表す. $c(i, j; 1)$ の場合と同様に, 1 はパターン 1 を意味する. 最後にパターン 1 を選択することの価値を定義する. 移動距離において, 個人が最短経路で移動した場合と, パターン 1 のライドシェア選択した場合の変化分を価値として定義する. つまり $v(i, j; 1) := c_u(i) + c_u(j) - c(i, j; 1)$ である. 最後にパターン 1 を選択した際にライドシェアして移動した分のコストを $s(i, j; 1) := d_{p_j, d_i}$ で表す. これらの定義は Π の各パターンについてそれぞれ定義される.

これまでの研究 [6] では以下のことが知られている.

定理 1 ([6]). ある 2 者 i, j について, 以下の 2 式が成り立つ.

$$\arg \max_{\pi \in \Pi} v(i, j; \pi) = \arg \min_{\pi \in \Pi} r(i, j; \pi) = \arg \min_{\pi \in \Pi} s(i, j; \pi) \quad (1)$$

$$v(i, j; \pi) + r(i, j; \pi) = s(i, j; \pi) \quad (2)$$

定理 1 により, ライドシェアを考える際には, 自然にあるパターン π が選ばれると想定してよい. そのため RPM 問題など

2: 共有可能性の文脈では直列なパターン $ijij, jiji$ は考慮しない

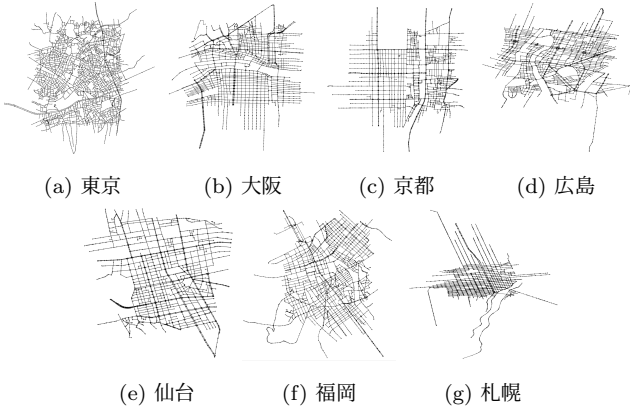


図 2: 東京・大阪・京都・広島・仙台・福岡・札幌の道路ネットワーク

のライドシェアを対象とした研究では、車両と顧客で構成した二部グラフ上の最大重みマッチングがしばしば利用される。上記の定理 1 の下で、式 (1) や式 (2) で付加した π を省略して、単に $v(i, j)$ などと表記する。また $v > 0$ であるとき、正のマッチと呼ぶ。仮に $v \leq 0$ であるとき、 i, j がライドシェアする動機は、移動コストの観点からは存在しない。

c) 評価指標

多数のリクエスト \mathcal{R} が所与のとき、2 者 $i, j \in \mathcal{R}$ について共有可能性解析を繰り返すことで、次のような値を計算することができる。

- $\mathbb{P}(v > 0)$: マッチする確率 (パターン (a) 以外)
- $\mathbb{P}(r = 0 \mid v > 0)$: 迂回が必要ない割合 (パターン (b))
- $\mathbb{E}[r \mid v > 0] / \mathbb{E}[c_u(i)]$: 期待移動距離に対して、迂回が生じる場合の距離割合
- $\mathbb{E}[v \mid v > 0] / \mathbb{E}[c_u(i)]$: 期待移動距離に対して、ライドシェアの価値の距離割合

例えばニューヨークのマンハッタン島の道路ネットワーク上で実データを用いた評価 [6] では $\mathbb{P}(v > 0) = 12.4\%$, $\mathbb{P}(r = 0 \mid v > 0) = 0.16\%$ である。そのため世の中のライドシェアサービスでは一定の迂回の下で価値のある車両の共有が行われる。

d) 例題

図 2 に示す OpenStreetMap より取得した 7 都市の道路ネットワーク³に対して、ランダムな乗降車位置によって生成した \mathcal{R} ($|\mathcal{R}| = 10,000$) を用いて、上の評価値を計算した例を図 3 に示す。ただし図中の横軸は、道路ネットワークが格子に近いかどうかを示す評価量 [3] であり、値が小さいとより無秩序に、大きいと格子グラフに近いことを意味する。

2.3 分布間の距離としての Wasserstein 距離と重心

本節では G 上のリクエスト集合 \mathcal{R} を特徴づけるために、機械学習の分野で近年注目されている Wasserstein 距離と重心を用いる。Wasserstein 距離や Optimal Transport については [9] などにまとめられているため、本節では本稿で利用する最低限




図 3: 7 都市の道路ネットワークを用いた評価指標の計算例

の定義だけ説明する。

ベクトル $\mathbf{a} \in \mathbb{R}^n$, $\sum_i a_i = 1$ と $\mathbf{b} \in \mathbb{R}^m$, $\sum_j b_j = 1$ の間で輸送を考え、点間のコストが $C \in \mathbb{R}^{n \times m}$ で与えられるとする。最適輸送問題とは以下の線形計画問題である。

$$\min_{P \in \mathbb{R}^{n \times m}} \sum_{i,j} C_{ij} P_{ij} \quad \text{s.t.} \quad P_{ij} \geq 0, \sum_j P_{ij} = a_i, \sum_i P_{ij} = b_j \quad (3)$$

式 (3) の最適解による目的関数値を用いて、2 つの離散分布 \mathbf{a}, \mathbf{b} 間の類似度を測定することができる。本稿では式 (3) で計算される 2 つの分布間の最適輸送距離を $\text{OT}(\mathbf{a}, \mathbf{b})$ で表す。

次に Wasserstein 重心 (Wasserstein Barycenter) を定義する。これは点の重心計算を拡張し、複数の分布の重心に相当する分布を計算したり、重みに応じて補間したりする際に適用できる技術である。今、 N 個の離散分布 $\{\mathbf{a}^{(i)}\}_{i=1}^N$ と重み $\lambda_i \geq 0$, $\sum_i \lambda_i = 1$ が所与の際、

$$\mathbf{v}^* := \arg \min_{\mathbf{v}} \sum_{i=1}^N \lambda_i \text{OT}(\mathbf{a}^{(i)}, \mathbf{v}) \quad (4)$$

で表されるような分布 \mathbf{v}^* を Wasserstein 重心と呼ぶ。Wasserstein 重心の直感的な説明として $\lambda_1 = \frac{1}{2}$, $\lambda_2 = \frac{1}{2}$ について

$$\tilde{\mathbf{v}}^* := \arg \min_{\mathbf{v}} \left(\frac{1}{2} \text{OT}(\mathbf{a}^{(1)}, \mathbf{v}) + \frac{1}{2} \text{OT}(\mathbf{a}^{(2)}, \mathbf{v}) \right)$$

の具体例を考えると、求まる分布 $\tilde{\mathbf{v}}^*$ は、Wasserstein 距離の意味で $\mathbf{a}^{(1)}$ と $\mathbf{a}^{(2)}$ の両方に同じ重みで近いような分布である。重み λ_i を変化させながら式 (4) を繰り返し解くことで、入力分布 $\mathbf{a}^{(i)}$ の間を輸送距離の意味で補間することができる。

2.4 本稿の対象とする問題

今、ライドシェアサービスの状況が (G, \mathcal{R}) で表現されるとする。このとき 2.2 節で述べた手法やシミュレータなどを用いて、サービスの KPI 評価値 (顧客の待ち時間、サービスの利益など) や性質を表す数値 (マッチする確率 $\mathbb{P}(v > 0)$ など) を取得することを、本稿では順方向の解析と呼ぶ。我々の目的はこの順方向の解析に対して逆方向の解析 (逆解析) を行うアプローチについて検討することであった。

本稿ではサービスエリアに対応する G は固定とした上で、リクエスト \mathcal{R} によってサービスがどのような挙動を示すのかを解析する問題を扱う。以下にマッチする確率 $\mathbb{P}(v > 0)$ に注目した逆解析問題の定式化を示す。

問題 1 (ライドシェアサービス逆解析問題 (直感的な説明)). 入力として (G, \mathcal{R}) と目標値 v^* が与えられたとき、 $\mathbb{P}(v > 0) > v^*$ になるような集合 \mathcal{R}' を提示する問題。

³: 東京, 大阪, 京都, 広島, 福岡, 仙台, 札幌の 7 都市の中心緯度経度に対して、左右 1km 四方の 2km 四方の領域を取得した。

どのような KPI や目標値を選定するかはサービスに依存する。本稿では具体的な例ではなく、理論的な共有可能性解析で用いられるマッチする確率 $\mathbb{P}(v > 0)$ などを対象として、様々な \mathcal{R} を探索するために分布を探索するアプローチを提案し、議論を行う。なお本稿では対象地域 G は固定されているとする。

3 ライドシェアの挙動観察のための探索手法

3.1 分布探索によるアプローチ

リクエストの集合 \mathcal{R} が G 上の分布に従って生成されていると仮定すると、様々な分布を探索することでリクエストを生成するアプローチを考えることができる。例えば [6] では、理論的な議論を行う場合にはランダムな乗降車分布を用いている。また実際のサービスの例題解析では、実データのサンプルを利用しているため [6, 10]、実データから計算した経験分布を用いた解析を行っているとして解釈できる。

以下に提案手法のフローを示す。

- (1) 対象地域を $G = (V, E, w)$ とする。乗車位置を表す V 上の離散分布を \mathbf{p} 、降車位置を表す分布を \mathbf{d} とする。
- (2) (\mathbf{p}, \mathbf{d}) からサンプリングした M 個のリクエスト対に対してライドシェアの指標を計算する。指標がユーザーにとって条件を満たす結果である場合、処理を終了する。
- (3) 現在の分布対 (\mathbf{p}, \mathbf{d}) とは異なる新しい分布対 $(\mathbf{p}', \mathbf{d}')$ を作成し、処理 (2) を繰り返す。

提案手法の中で、新しい分布対 $(\mathbf{p}', \mathbf{d}')$ を生成する方法が必要になる。例えば既存研究 [10] の知見に従うと、リクエストの集合 \mathcal{R} の偏りがライドシェアサービスに影響を与える。つまり乗降車位置が近接しており、同じ方向へ移動するリクエストが多いと、ライドシェアによる価値が大きくなると考えられている。そこで無情報な分布としてランダムな乗降車分布から探索をはじめ、徐々に偏った乗降車分布を探索した上で共有可能性解析を繰り返すことで、ライドシェア全体の挙動を観察し、探索を行う。このような探索アプローチを 3.2 節に提案する。

3.2 2点間の補間に基づく手法

本節では2つの対となる分布 (\mathbf{p}, \mathbf{d}) と $(\mathbf{p}', \mathbf{d}')$ を用意し、その間を補間するような分布を生成することで、2つの分布間を直線的に探索するアプローチを提案する。先に述べたとおり、 (\mathbf{p}, \mathbf{d}) はランダムな分布とする。一方で $(\mathbf{p}', \mathbf{d}')$ は既存研究の知見に従って偏った分布を作成して用いる。

a) 線形補間

分布を表現するために、 V 上の離散分布を考え、 $\mathbf{p} = (p_1, \dots, p_{|V|})$ で表す。ランダムな分布では $p_i = \frac{1}{|V|}$ である。偏った分布を表現する際、 V 全域ではなく一部の頂点集合 $V' \subseteq V$ のみから乗降車需要が発生すると仮定し、同様に $\mathbf{p}' = (p'_1, \dots, p'_{|V|})$ で表す。ただし $\sum_{j=1}^{|V|} p'_j = 1$ かつ $p'_k = 0$ ($k \notin V'$) である。このとき2つの離散分布 \mathbf{p}, \mathbf{p}' の間を線形補間するために、 $\mathbf{p}_{\lambda_1}^{\text{Lin}} := (1 - \lambda_1)\mathbf{p} + \lambda_1\mathbf{p}'$ ($0 \leq \lambda_1 \leq 1$) とし、リクエスト \mathcal{R} を生成して評価を行う。




図 4: 線形補間に基づく補間分布 $\mathbf{p}_{\lambda_1}^{\text{Lin}}$ を用いて 10 段階で生成したリクエストの例




図 5: 図 4 のデータから評価値を計算した結果

b) Wasserstein 重心を用いる補間

2.3 説で説明した Wasserstein 重心を用いて、確率分布の探索を行う。線形補間の場合と同様に、2つの分布 \mathbf{p}, \mathbf{p}' を用意し、2つの分布の補間として $\mathbf{p}_{\lambda_1}^{\text{W}} := \arg \min \{(1 - \lambda_1)\mathbf{p} + \lambda_1\mathbf{p}'\}$ を λ_1 に応じて計算し、リクエスト \mathcal{R} を生成して評価を行う。

4 実験

本章では図 2 で取り上げたネットワークを用いた計算機実験の結果を報告し、考察を述べる。我々の実装では偏った分布を作成するためにネットワークの頂点の部分集合 V' を選択する。 V' を選択するために、頂点の座標情報に対して k -means 法を適用し、 k 個のクラスタから 1 つを選択することで偏った分布の台とする。

4.1 例題

京都の道路ネットワークに対して本稿で提案した逆解析手法を適用する。実験ではクラスタ数を $k = 4$ と設定し、ランダムに 2 者を選んだ。3.2 節で述べたうち、線形補間に基づいて分布を 10 段階で補間し、リクエストを生成した結果を図 4 に示す。こうして生成した 10 個の分布を用いてリクエストの集合をサンプルし、評価値を計算したものを図 5 に示す。このように分布を変化させながら評価を行うことで、図 5 に示すように目標値の変化が観測できる。そのため我々の手法を用いることで、対象地域 G 上の需要分布という観点より、「どのような分布の場合に目標値が達成できたのか」を検証することができる。同時にシミュレーションに基づいて、サービスの目標値がライドシェアサービスの性質上満たすことができない数値となる可能性などが検証できる。

4.2 線形補間と Wasserstein 重心の比較

Wasserstein 重心を計算するとき、エントロピー正則化のパラメータ ϵ が存在する必要がある。本節では線形補間と $\epsilon = 0.05, 0.005$ による結果を比較する。図 6 に特に $\mathbb{P}(v > 0)$




図 6: 線形補間, Wasserstein 重心 ($\epsilon = 0.05, 0.005$ による $\mathbb{P}(v > 0)$ の結果比較






図 7: 3都市における $\mathbb{P}(v > 0)$ の平均的な挙動



(a) 東京 (tokyo) (b) 京都 (kyoto) (c) 広島 (hiroshima)

図 8: 3都市における $\mathbb{P}(r = 0 | v > 0)$ の平均的な挙動




(a) 東京 (tokyo) (b) 京都 (kyoto) (c) 広島 (hiroshima)

図 9: 3都市における $\mathbb{E}[r | v > 0] / \mathbb{E}[c_u(i)]$ の平均的な挙動

の結果を示す。結果より、線形補間では比較的なめらかに数値が推移したが、Wasserstein 重心を用いる場合には ϵ の影響を受ける。 ϵ の値が大きいとき、補間がよくなめらかになる傾向があり、線形補間に近くなるが値 $\mathbb{P}(v > 0)$ は若干小さくどどまった。一方で ϵ の値が小さいときは、補間が急に切り替わるようになり、推定値が大きく変動することが分かる。

4.3 3都市における平均的な挙動と考察



(a) 東京 (tokyo) (b) 京都 (kyoto) (c) 広島 (hiroshima)

図 10: 3都市における $\mathbb{E}[v | v > 0] / \mathbb{E}[c_u(i)]$ の平均的な挙動

本稿の提案手法は分布からリクエストをサンプルして評価を

行うため、結果は確率的な挙動を示す。本節では図 2 から「東京」「広島」「京都」の 3 都市を選び、ランダムサンプリングを 100 回繰り返した場合の平均的な挙動を確認する。図 7, 8, 9, 10 に 4 つの評価指標の結果をそれぞれ示す。これらの結果より、平均的な挙動としては次のことが言える。

まずはじめに、ライドシェアの最も基本的な指標であるマッチする確率 $\mathbb{P}(v > 0)$ については、図 7 に示すように、都市のトポロジ構造に依存することなく需要がある一定以上偏在している ($\lambda > 0.5$) と高い数値を取る。単にライドシェアの回数や割合を一定以上に高めたい場合には、需要の偏った状態において車両を適切に配車させる方策が効果的である。一方でランダムなリクエストと比較した場合の上昇幅は、都市の特徴が影響を与える可能性がある。

次に迂回が 0 である確率 $\mathbb{P}(r = 0 | v > 0)$ を確認すると、図 8 に示すように道路ネットワークを用いた実験では明確な傾向が見られない。そのためユーザ i ごとに許容できる迂回量 (時間や距離など) を入れた上で検証すると、より詳細な解析が可能であると考えられる。

ユーザの期待移動コスト $\mathbb{E}[c_u(i)]$ に対する、迂回距離やマッチにおける価値の割合は、図 9 と図 10 に示すとおり分布の偏在に関する横軸のパラメータ λ にともなう若干の減少・増加傾向が見られる。距離ベースでコストと価値を定義する現在のアプローチでは、平均的に図 9 の数値が図 10 の数値を上回るため、8 の結果と合わせて距離ベースの定式化ではライドシェアの利得が小さいことが分かる。そのため実サービスにおいてはシェアリングに対して需要喚起が必要である可能性が高い。

まとめると 4 つの評価量については、平均的な挙動は地域よりもリクエストの偏在性に依存する可能性が高いと考えられる。ただしシミュレーション実験によれば、変化の挙動や大きさは都市の構造から多少の影響を受けている可能性がある。例えば東京と京都のデータを比較すると、指標の変化量はより格子に近い京都の方で大きいことが分かる。

5 まとめ

本稿ではライドシェアの解析技術に着目し、ライドシェアに関する既存研究 [6] で用いられている評価値を対象として、評価値が一定の条件を満たすようなサービス状況は何かを逆解析するための枠組みについて検討を行った。提案手法はサービスのリクエスト分布を入力として受け取り、その対となる分布を探索しながらシミュレーション評価を繰り返しおこなうことで、マッチする確率や迂回が 0 になる確率などの評価値を確認しながら、どのような分布のサービス対象であれば良かったのかを探索するための手がかりとして、様々なランダムデータを生成し、探索的にシミュレーションを行う枠組みを構築した。

本稿の実験では、実際の道路ネットワークと均一にランダムな分布を用いた上で、[6] で用いられている評価値が探索においてどのような変化を生じるのかを確認した。特にマッチが発生する確率については、提案した分布の探索アルゴリズムによって数値の相転移が観察され、目標数値に対する探索可能性が示

唆された。その他の KPI やマッチングアルゴリズムとの連携については今後の課題である。本文中で述べたとおり、マッチによる利得と迂回によるコストはトレードオフの関係にあるため、今後は多目的最適化問題としてのマッチングアルゴリズムと、シミュレーションとの連携・逆解析などについて今後研究をすすめる予定である。

文 献

- [1] Javier Alonso-Mora, Samitha Samaranayake, Alex Wallar, Emilio Frazzoli, and Daniela Rus. On-demand high-capacity ride-sharing via dynamic trip-vehicle assignment. *PNAS*, Vol. 114, No. 3, pp. 462–467, 2017.
- [2] Arjun Balasingam, Karthik Gopalakrishnan, Radhika Mittal, Venkat Arun, Ahmed Saeed, Mohammad Alizadeh, Hamsa Balakrishnan, and Hari Balakrishnan. Throughput-fairness tradeoffs in mobility platforms. In *Proc. of the MobiSys2021*, pp. 363–375. ACM, 2021.
- [3] Geoff Boeing. Urban spatial order: Street network orientation, configuration, and entropy. *Applied Network Science*, Vol. 4, No. 1, pp. 1–19, 2019.
- [4] Regina R Clewlow and Gouri S Mishra. Disruptive transportation: The adoption, utilization, and impacts of ride-hailing in the united states. *Research Report UCD-ITS-RR-17-07*, 2017.
- [5] Sampo Hietanen. Mobility as a Service. pp. 2–4, 2014.
- [6] Ilan Lobel and Sebastien Martin. Detours in shared rides. *Available at SSRN 3711072*, 2020.
- [7] Meghna Lowalekar, Pradeep Varakantham, and Patrick Jaillet. Competitive ratios for online multi-capacity ridesharing. In *Proc. of the AAMAS2020*, pp. 771–779, 2020.
- [8] Nora Molkenhain, Malte Schröder, and Marc Timme. Scaling laws of collective ride-sharing dynamics. *Phys. Rev. Lett.*, Vol. 125, p. 248302, Dec 2020.
- [9] Gabriel Peyré and Marco Cuturi. Computational optimal transport: With applications to data science. *Foundations and Trends® in Machine Learning*, Vol. 11, No. 5-6, pp. 355–607, 2019.
- [10] Paolo Santi, Giovanni Resta, Michael Szell, Stanislav Sobolevsky, Steven H Strogatz, and Carlo Ratti. Quantifying the benefits of vehicle pooling with shareability networks. *PNAS*, Vol. 111, No. 37, pp. 13290–13294, 2014.
- [11] Sanket Shah, Meghna Lowalekar, and Pradeep Varakantham. Neural approximate dynamic programming for on-demand ride-pooling. In *Proc. of the AAAI*, Vol. 34, pp. 507–515, 2020.
- [12] Remi Tachet, Oleguer Sagarra, Paolo Santi, Giovanni Resta, Michael Szell, Steven H Strogatz, and Carlo Ratti. Scaling law of urban ride sharing. *Scientific reports*, Vol. 7, No. 1, pp. 1–6, 2017.