

# 反実仮想機械学習を用いた タクシーの乗車数予測と配置最適化

松井 諒生, 住谷 有規, 笹尾 知広, 中田 和秀

## 1. はじめに

タクシー業界が抱える深刻な課題としてドライバー不足が挙げられる。ドライバー不足はタクシー事業者の売上を減少させるだけでなく、乗車機会の減少によって、交通インフラとしての役割を損なわせる恐れがある。しかし、ドライバーを増やすとしても、働きやすさや賃金といった面で労働環境に壁がある。さらに、後藤 [1] は、日本のタクシー業界は他の産業と比較して労働生産性が低いことを示唆している。

そこで本研究では、労働環境を考慮しながら労働生産性を高めることを目指す。労働生産性を高めるために、乗車数が増えるように空車タクシーの配置を最適化する。この配置最適化を行うためには乗車数の情報を必要とするため、空車タクシーの台数に応じた乗車数の予測を行う。ただし、配置最適化によって空車タクシー数を変化させる（介入する）ことが予測の精度に悪影響を与える。この問題を解決するため、本研究では反実仮想 [2] の枠組みを応用した機械学習によって予測を行う。また、空車タクシーの配置最適化を行う際は、実用性を担保するため二段階で最適化を行うことを提案する。

最後に、提案手法の有効性を調べるため、令和元年度データ解析コンペティションにおいてみずほ情報総研株式会社から提供された都内タクシーのプローブデータ（緯度・経度、ドライバー ID、所属企業 ID、状態など）を用いて検証を行う。

## 2. 関連研究

本節では、需要予測に関する既存研究と需要予測の応用例（今回では配置最適化）に関する既存研究を紹介し、本研究との関係について述べる。

まつい りょう, すみや ゆうき, ささお ともひろ, なかた かずひで  
東京工業大学工学院経営工学系  
〒152-8552 東京都目黒区大岡山 2-12-1  
受付 20.7.25 採択 20.11.5

### 2.1 需要予測

タクシーの需要予測については Yao et al. [3] が需要の時系列性と乗車地の空間的關係を考慮した DMVST-Net を提案している。この研究では配車アプリのデータを需要として扱っているが、本研究ではタクシーのプローブデータを扱っているため需要ではなく乗車数しか観測できない。また Afian et al. [4] のプローブデータを用いた研究では、観測できない需要（需要があったとしても供給がなければ乗車として観測されない）を待ち行列モデルを用いて予測している。つまり、タクシーの需要量・供給量・乗車数の関係は自明なものではなく、分析に当たってその関係性を考慮する必要がある。

また今回は配置最適化のために、空車タクシーの台数（供給量）を変化させたときの乗車数（乗車数曲線）の予測を行う。これは、乗車数に対する空車数の介入効果を捉えることだと言いかえられる。必要なデータの一部しか手に入らない状況で介入効果を測定する方法として、近年、反実仮想機械学習 (Counterfactual Machine Learning, CFML) の研究が進んでいる [5-7]。従来の CFML の研究は推薦システムやランキング学習での応用を中心としているが、本研究ではその枠組みを制約付き最適化と組み合わせた教師あり機械学習に応用する。

### 2.2 需要予測の応用例

タクシーの需要や乗車数を予測することができればさまざまな応用が可能となる。Yan et al. [8] は需要予測の結果を踏まえ、ドライバーと利用者のマッチング、需要・供給のバランスから価格を変動させるダイナミックプライシングについて分析した。また需要がある地域に予め空車タクシーを配置しておくことで、移動距離・空車時間を削減する車両のリバランシング問題についても多くの研究がされている [9, 10]。しかし従来の研究では需要を満たすための車両移動のみを考えており、個々人のドライバーの効用や働き方が考慮されていなかった。また 2.1 節でも述べたとおり、

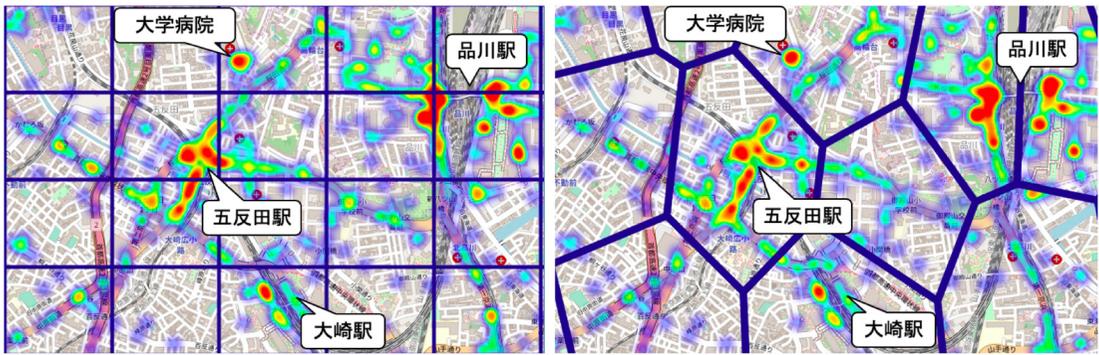


図 1 (左) 標準メッシュによる領域分割 (右) BIRCH による領域分割

プローブデータで観測できる乗車数はタクシーの供給量で変化するが、それを考慮した空車タクシーの配置最適化の研究は報告されていない。本研究は供給量によって変化する乗車数と個々人のドライバーを考慮した初めての研究だといえる。

### 3. 提案手法

本節では、反実仮想機械学習を用いて乗車数を予測し、その予測値に基づいてタクシーの配置最適化を行う方法について説明する。3.1 節で反実仮想機械学習を用いた乗車数予測の方法、3.2 節でタクシー配置の最適化法について述べる。

#### 3.1 乗車数予測

一般的に乗車数予測や需要予測では、地域や時刻についての特徴量  $X$  から乗車数  $r$  を予測する。しかし、本研究では乗車数を最大化するように配置最適化を行うため、空車タクシー数  $e$  を変化させることになる。そのため、過去の空車タクシー数を前提に乗車数を予測すれば良いのではなく、任意の空車タクシー数に対して乗車数を予測する必要がある。すなわち、特徴量  $X$  と空車タクシー数  $e$  を用いて乗車数  $r$  の予測モデル

$$r \approx f(X, e)$$

を構築することになる。次節では、まず特徴量  $X$  の生成方法について説明し、その後で乗車数の予測モデル  $f(X, e)$  の構築法について説明を行う。

##### 3.1.1 特徴量の生成

本研究では、各時刻において地域別に予測を行うことにする。よって、地域の集合を  $\mathcal{A} = \{a_1, a_2, \dots, a_n\}$ 、タイムステップの集合を  $\mathcal{T} = \{t_1, t_2, \dots, t_m\}$  としたときに、 $i = (a, t) \in \mathcal{A} \times \mathcal{T}$  に対する特徴量  $X_i$  を生成する。そのため、まず集合  $\mathcal{A}$  および  $\mathcal{T}$  を定義し、次に  $\mathcal{A}$ ,  $\mathcal{T}$  それぞれに関する特徴量を定めるという手順

をとる。

タイムステップの集合  $\mathcal{T}$  については分析問題に応じて適切な時間間隔を選べば良いので、非自明な  $\mathcal{A}$  の取り方について考える。最も単純な地域の分割方法としては、標準地域メッシュ [11] による分割が考えられる。図 1 (左) は、標準地域メッシュのうち、4 次メッシュと呼ばれる分割と各地域での乗車状況を示すヒートマップである。この図からもわかるとおり、このような標準地域メッシュでは乗車状況を捉えた領域分割はできない。これに対してわれわれは、領域をそれぞれ同程度の大きさに分割できる BIRCH [12] によって地域  $\mathcal{A}$  を定義する方法を採用した。このアルゴリズムは直径が一定のしきい値以内のデータを縮約し部分クラスタを生成する。また、計算時間のオーダーがデータ数に対して線形となるため、大規模データに適したクラスタリングである。図 1 (右) は図 1 (左) と同様に、乗車状況のヒートマップと BIRCH による領域分割を表している。標準地域メッシュと比較して駅や病院の乗車状況を捉えていることが確認できる。

これによって、 $\mathcal{A}$  および  $\mathcal{T}$  の定義が決まったので、次にこれらの各要素について特徴量を設定する。最も基本的な情報として、地域に関しては緯度/経度/タクシーストップ数/駅数、タイムステップに関しては時刻/曜日/天気/天気予報/鉄道事故などが使用できると考えられる。しかし、これらのみでは乗車数の傾向や都市機能の類似性を考慮できない。これを考慮するために、本研究では地域についての特徴量として、

- (a) 各地域の乗車数の時系列変化
- (b) タクシー利用者の地域間の移動傾向

という二つの情報を追加することを提案する。(a) について、各地域について 1 日の乗車数の平均を 30 分間隔で計算し、得られた 48 次元のベクトルから冗長な表現を削減するため低次元に圧縮するという方法をとる。

この次元圧縮は fuzzy c-means [13] および t-SNE [14] で行った。fuzzy c-means はソフトクラスタリングの一種であり、各クラスタに対して所属割合を算出できるため、この所属割合を特徴ベクトルとする。また、t-SNE は、ベクトル同士の（ユークリッド）距離を保つように 2, 3 次元に圧縮する方法である。(b) について、タクシー利用者の地域間の移動を推移確率行列として表し、node2vec [15] を用いて地域ごとの特徴量を生成した。node2vec は重み有向グラフからノード間の機能の類似性を算出し、各ノードに対する分散表現を獲得する方法である。他のグラフ埋め込み手法と比較して、ノードがもつ役割（隣接するノードの数や辺の方向関係）を強く考慮して分散表現を獲得できる手法である。

### 3.1.2 反実仮想機械学習に基づく乗車数予測

次に、3.1.1 節で得られた特徴量  $X_i (i \in \mathcal{I} = \mathcal{A} \times \mathcal{T})$  と実現可能な空車数  $e \in \mathcal{E} = \{0, 1, \dots, e_{max}\}$  を用いた乗車数の予測モデルについて考える。

地域と時刻を定めると、実現した空車数は一つしかない。よって、それ以外の多くの空車数に対する乗車数を観測することは不可能である。このような偏った一部のデータを使って予測モデルを学習する場合、学習データと近い環境では予測の精度が保たれるものの、それ以外の環境では精度が悪化するという問題が発生する。これは配置最適化によって空車数を変化させたときに、精度の悪い予測値を使用することを意味する。よって配置最適化を前提とした乗車数予測を行うのであれば、過去に発生した空車数に依存せず、すべての空車数に対して正確に乗車数を予測できるようにする必要がある。

そこで本研究では、観測できない事象に関して潜在的な結果を仮想的に考える反実仮想の枠組みによってこの問題の解決を図る。このように機械学習と反実仮想を組み合わせる手法は反実仮想機械学習と呼ばれる。反実仮想機械学習の枠組みに沿って乗車数予測モデルを構築するため、以下では学習に当たって最小化する「誤差」について考えていく。

#### 理想的経験誤差

仮に過去に観測された特徴量  $X_i$  とすべての実現可能な空車数  $e$  に対して、乗車数  $r_{i,e}$  が観測できていたとしよう。このとき、予測値  $\bar{r}_{i,e}$  に対する誤差として、次のものを考えるのが自然である。

$$\mathcal{L}_{ideal} = \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{i \in \mathcal{I}} \sum_{e \in \mathcal{E}} (r_{i,e} - \bar{r}_{i,e})^2$$

以下ではこの誤差を理想的経験誤差と呼ぶことにする。想定する予測モデルの集合を  $\mathcal{F}$  としたとき、この理想的経験誤差を用いた学習は次の最適化モデルで表すことができる。

$$\begin{aligned} \min \quad & \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{i \in \mathcal{I}} \sum_{e \in \mathcal{E}} (r_{i,e} - \bar{r}_{i,e})^2 \\ \text{where} \quad & \bar{r}_{i,e} = f(X_i, e) \quad (i \in \mathcal{I}, e \in \mathcal{E}), \\ & f \in \mathcal{F}. \end{aligned}$$

しかし、先述したように実際には多くの  $r_{i,e}$  が観測されていないため、この学習を行うことはできない。このため、理想的経験誤差の不偏推定量となる誤差、すなわち  $\mathbb{E}[\mathcal{L}] = \mathcal{L}_{ideal}$  となるような誤差  $\mathcal{L}$  を用いて学習することが望ましい。

#### 経験誤差

計算可能な誤差として最も標準的なものは、観測されたデータを使った平均二乗誤差である。これは通常、経験誤差と呼ばれる。説明に先立ち、観測の有無を表現するインジケータ  $O_{i,e} \in \{0, 1\}$  を導入する。これは  $(X_i, e)$  のペアが、観測されているときに 1、観測されていないときに 0 をとる。また、これを用いて観測したペアの集合を  $\mathcal{O} = \{(i, e) : O_{i,e} = 1\}$  と表す。この集合を用いると、経験誤差は次のように記述することができる。

$$\mathcal{L}_{naive} = \frac{1}{|\mathcal{O}|} \sum_{(i,e) \in \mathcal{O}} (r_{i,e} - \bar{r}_{i,e})^2$$

しかし、観測される  $(X_i, e)$  のペアには偏りがあり、 $O_{i,e} = 1$  をとる確率は  $i$  と  $e$  に依存することが予想される。実際、ドライバーは客を乗せやすい場所に移動すると考えられる。そのため、ある地域のある時刻では空車数が多く、別の地域の別の時刻では空車数が少ないという状況が観測される。このとき、一般に  $\mathbb{E}[\mathcal{L}_{naive}] \neq \mathcal{L}_{ideal}$  となり、経験誤差  $\mathcal{L}_{naive}$  は不偏性を満たさない。よって、標準的な経験誤差を用いて学習するのは、配置最適化を考えた場合ふさわしくないことがわかる。

#### IPS 誤差

このように観測データ  $(X_i, e)$  に偏りがある場合、そのバイアスを除去する方法として逆傾向スコア (Inverse Propensity Score, 以下 IPS) で重み付けをするという手法がある [5]。傾向スコアは、環境  $X_i$  のもと、空車数  $e$  が発生する確率  $P(e|X_i)$  として定義され、すなわち  $O_{i,e} = 1$  を取る確率と一致する。そしてこの傾向スコアの逆数 (IPS) で重み付けした誤差として

$$\mathcal{L}_{IPS} = \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{(i,e) \in \mathcal{O}} \frac{(r_{i,e} - \bar{r}_{i,e})^2}{P(e|X_i)}$$

と定義する（これを IPS 誤差と呼ぶ）。このとき、

$$\begin{aligned} \mathbb{E}[\mathcal{L}_{IPS}] &= \mathbb{E} \left[ \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{(i,e) \in \mathcal{O}} \frac{(r_{i,e} - \bar{r}_{i,e})^2}{P(e|X_i)} \right] \\ &= \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{i \in \mathcal{I}} \sum_{e \in \mathcal{E}} \mathbb{E}_{O_{i,e}} \left[ \frac{O_{i,e}(r_{i,e} - \bar{r}_{i,e})^2}{P(e|X_i)} \right] \\ &= \frac{1}{|\mathcal{I}||\mathcal{E}|} \sum_{i \in \mathcal{I}} \sum_{e \in \mathcal{E}} P(e|X_i) \frac{(r_{i,e} - \bar{r}_{i,e})^2}{P(e|X_i)} \\ &= \mathcal{L}_{ideal} \end{aligned}$$

が成り立つため、 $\mathcal{L}_{IPS}$  は不偏性を満たす。よって、誤差  $\mathcal{L}_{IPS}$  を最小化するという学習を行い、予測モデル  $f(X, e)$  を構築することにより、配置最適化に適合した予測を行うことが可能となる。なお、傾向スコアに用いる特徴量  $X$  と乗車数の予測に用いる特徴量  $X$  を別のものにする 것도可能である。本論文では、何らかの予測に利用できる特徴量すべてを含んだ存在として  $X$  を捉えているため、両方に共通の  $X$  を用いている。

### 3.1.3 傾向スコアの推定

前節では傾向スコアを  $P(e|X)$  として定義したが、より一般的には、ある条件が定められたときに特定の介入を受ける確率を意味する。しかし、このような傾向スコアは多くの場合未知であり、乗車数  $r$  とは別に推定する必要がある。傾向スコアの推定方法として、Schnabel et al. [5] はロジスティック回帰、Liang et al. [16] はナイーブベイズおよびポアソン行列分解による推定方法を示した。このロジスティック回帰およびナイーブベイズという二つの方法は、介入がバイナリの際に有効である。しかし、本研究で扱う介入は空車数  $e$  という非負離散値であるため適用することができない。一方、ポアソン行列分解は介入として非負離散値を扱うものの、行列分解をベースとした手法のため、こちらも相応しくない。また、Kallus and Zhou [17] が示した手法は、介入が連続値である場合にのみ有効である。そこで本研究では傾向スコアの推定法として、ポアソン損失を用いた教師あり機械学習を採用する。ポアソン損失を用いる理由は、空車数は非負整数値を取り確率値が計算しやすいことと、予備実験の結果、空車数の分布がポアソン分布に近かったということによる。さらに、この方法は一般化線形モデルの一つであるポアソン回帰を非線形モデルに拡張したものと言える。具体的には、非線形関数  $g$  を用いて表される確率

モデル

$$P(e|X) \sim \text{Pois}(g(X))$$

を仮定し、任意の  $i \in \mathcal{I} = \mathcal{A} \times \mathcal{T}$  で観測されたデータについて対数尤度を最大化する問題、

$$\begin{aligned} \max \quad & \sum_{i \in \mathcal{I}} e_i \log(\bar{e}_i) - \bar{e}_i \\ \text{where} \quad & \bar{e}_i = \exp(g(X_i)) \quad (i \in \mathcal{I}), \\ & g \in \mathcal{G}. \end{aligned}$$

を解くことによって  $g$  を求める。ただし、 $\mathcal{G}$  は乗車数予測の定式化と同様に想定する推定モデルの集合を表し、 $e_i$  は  $i \in \mathcal{I}$  において観測された空車数を表す。

以上、3.1 節をまとめると、

- 乗車数時系列変化および地域間の移動情報の利用
  - IPS で重み付けした誤差を用いた学習
  - ポアソン損失の機械学習による傾向スコアの推定
- という 3 点が本研究での提案といえる。

## 3.2 配置最適化

前節で説明した乗車数予測モデルの出力結果を用いて、空車タクシーの配置最適化を行う。タイムステップ  $t_m$  における配置最適化は、本来ならば  $t_m$  の開始時にタクシーの位置情報の取得、最適化計算および指示を行うのが理想であるが、この操作には多少の時間が見込まれるため、本研究では一つ前のタイムステップ  $t_{m-1}$  の終盤に行うものとする。

### 3.2.1 目的およびアプローチ

配置最適化の目的およびそれらの具体的な項目を表 1 にまとめた。これらの目的に対するアプローチを考える。まず目的 1 のみを考えればドライバーを同質な資源とみなした資源配分問題として捉えることができる。また目的 2・目的 3 については、各々のドライバーが満足するように地域を指定する割当問題として捉えることができる。これら三つの目的をすべて達成するために両問題を一つの問題として解くことが考えられるが、これは計算時間やパラメータ調整の観点から実用的に難しい。そこで、本研究では資源配分問題と割当問題を 2 段階で最適化することで、すべての目的を達成させる。

表 2 に、配置最適化で用いる記号の定義を示す。変数について、 $x_{i,j,k}, z_{i,i'}$  は現実的な移動距離のもと、 $y_{i,e}$  については一定以上の傾向スコアのもと（傾向スコアがあまりにも小さいと予測精度が保証できない）、定義の制限を行う。このように不必要な（もとより値が 0 であることが期待されている）変数を事前に削除することにより、計算時間を削減できることが期待さ

表 1 配置最適化の目的および具体的項目

目的	具体的項目	説明
1. 全体の乗車数最大化	期待乗車数	予測に基づく乗車数を用いる.
2. 個別の労働環境の維持・改善	ドライバーの地域に対する効用	希望する地域で働ける可能性を高める.
	ドライバー間の乗車数の公平性	ドライバー間の賃金格差を防ぎ、労働環境を維持.
3. 実用性の確保	計算時間	タイムステップごとに配置を決定するため、計算時間を抑えたい.
	企業間の乗車数の公平性	複数企業を同時に扱うときに、格差があっては実用的に問題である.
	流し・待ち受け <sup>1</sup> の指示	地域によって流しと待ち受けで乗車数比率が異なる. これも指示しなければドライバーに混乱が生じる.

<sup>1</sup> 流しとは、車道を走行しながら客を見つけること。待ち受けとは、タクシー乗り場などで停車して客を待つこと。

表 2 配置最適化で用いる記号の定義. 上段から集合, 変数, 定数, 関数を示す.

記号	説明
$\mathcal{A} = \{a_1, a_2, \dots\}$	地域の集合.
$\mathcal{E} = \{0, 1, \dots, e_{max}\}$	空車数の集合.
$\mathcal{A}' \subseteq \mathcal{A}$	流し・待ち受けを指定する地域の集合.
$\mathcal{C} = \{c_1, c_2, \dots\}$	タクシー企業の集合.
$\mathcal{D} = \{d_1, d_2, \dots\}$	ドライバーの集合. ただし、各ドライバーはいずれかの企業一つに属するものとする.
$y_{i,e} \in \{0, 1\}$	$a_i \in \mathcal{A}, e \in \mathcal{E}$ . 1 なら地域 $a_i$ に配置する空車タクシー数が $e$ である. ただし配置に際し一定の傾向スコア $p_{min}$ を下回るものは定義しないものとする.
$z_{i,i'} \in \mathbb{N}$	$a_i, a_{i'} \in \mathcal{A}$ . 地域 $a_i$ から $a_{i'}$ に移動する空車タクシー数. ただし移動に際し一定の距離 $l_{max}$ を上回るものは定義しないものとする.
$x_{i,j,k} \in \{0, 1\}$	$a_i \in \mathcal{A}, d_j \in \mathcal{D}, k \in \{0, 1\}$ . 1 ならドライバー $d_j$ を地域 $a_i$ に状態 $k$ (0: 流し/1: 待ち受け) で配置. ただし $k=0$ は「流し」を、 $k=1$ は「待ち受け」を意味する. 移動に際し一定の距離 $l_{max}$ を上回るものは定義しない. また、 $a_i \notin \mathcal{A}'$ ならば $x_{i,j,1}$ を定義しない.
$\lambda > 0$	調整可能なパラメータ. 極めて小さい値を設定する.
$n_i \in \mathbb{N}$	$a_i \in \mathcal{A}$ . 地域 $a_i$ の直前のタクシー数.
$\bar{r}_{i,e} \geq 0$	$a_i \in \mathcal{A}, e \in \mathcal{E}$ . 地域 $a_i$ に空車数 $e$ を割り当てたときの期待乗車数.
$l_{i,i'} \geq 0$	$a_i, a_{i'} \in \mathcal{A}$ . 地域 $a_i, a_{i'}$ 間の距離.
$\lambda_1, \dots, \lambda_5$	調整可能なパラメータ.
$u_{i,j} \geq 0$	$a_i \in \mathcal{A}, d_j \in \mathcal{D}$ . ドライバー $d_j$ が地域 $a_i$ に配置される効用 (地域効用). 事前にアンケートなどで調査して入手する.
$u_j^+ \geq 0$	$d_j \in \mathcal{D}$ . ドライバー $d_j$ のその日の累積の地域効用.
$r_j^+ \geq 0$	$d_j \in \mathcal{D}$ . ドライバー $d_j$ のその日の累積の乗車数.
$0 \leq v_j \leq 1$	$d_j \in \mathcal{D}$ . ドライバー $d_j$ の流しへの効用. なお、 $1 - v_j$ は待ち受けへの効用である. 事前にアンケートなどで調査して入手する.
$0 \leq f_i \leq 1$	$a_i \in \mathcal{A}$ . 地域 $a_i$ の流し割合. ただし、 $a_i \notin \mathcal{A}'$ なら $f_i = 1$ とする.
$\hat{r}_i \geq 0$	$a_i \in \mathcal{A}$ . 1 段階目で得た地域 $a_i$ の期待乗車数.
$\hat{y}_i \geq 0$	$a_i \in \mathcal{A}$ . 1 段階目で得た地域 $a_i$ の割当空車数. ここで $\hat{r}_i/\hat{y}_i$ は地域 $a_i$ の乗客の獲得しやすさを表す.
$R(\cdot)$	値を四捨五入する関数.

れる. 本研究の検証においてはこの制限によって、変数の数を約 96%削減している.

### 3.2.2 1 段階目の定式化

目的 1 を達成するため、1 段階目の資源配分問題を整数計画問題として定式化する. これを解くことにより、各地域に配置する空車タクシー数が決まる. 表 2 の記号を用いて、1 段階目の資源配分問題を定式化すると次のようになる.

$$\begin{aligned} \max. & \sum_{a_i} \sum_e \bar{r}_{i,e} \cdot y_{i,e} - \lambda \sum_{a_i} \sum_{a_{i'}} l_{i,i'} \cdot z_{i,i'} \\ \text{s.t.} & \sum_e e \cdot y_{i,e} = \sum_{a_{i'}} z_{i,i'}, \\ & \sum_e y_{i,e} = 1, \quad \sum_{a_{i'}} z_{i,i'} = n_i \quad (a_i \in \mathcal{A}). \end{aligned}$$

ここで  $z_{i',i}$  は地域  $a_{i'}$  から地域  $a_i$  に移動する空車

タクシー数であるが、 $i' = i$  のときはこれを地域  $a_i$  に残る空車タクシー数として捉えることができる. よって、制約条件の一つ目は、各地域に配置する空車タクシー数が「その地域に残る数 + 他地域からの流入数」と一致することを保証するものである. また、目的関数は全体の乗車数 (目的 1) である.  $\lambda$  が十分小さい値であれば、各地域に配置する台数  $y_{i,e}$  が決められた中で、各  $z_{i,i'}$  は空車タクシーの移動距離の和が最小となるように決定される. しかし本来、移動距離が最小である必要はなく、ある一定以下の移動距離であれば労働環境などを考慮して、より好ましい位置に配置してもよいと思われる. したがって 2 段階目の割当問題では、1 段階目で得られた  $y_{i,e}$  を制約にして、新たに配置を決定し直す問題として考える.

### 3.2.3 2段階目の定式化

目的2・目的3を達成するため、2段階目の割当問題を混合整数計画問題として定式化する。これは先述の1段階目の結果を利用して行う最適化であり、各地域の配置数を満たすように各ドライバーの移動を決定する。表2の記号を用いて、2段階目の割当問題を定式化すると次のようになる。

$$\begin{aligned}
 \max. \quad & \lambda_1 \frac{\sum_{a_i} \sum_{d_j} \sum_k u_{i,j} \cdot x_{i,j,k}}{|D|} \\
 & + \lambda_2 \min_{d_j} \left( u_j^+ + \sum_{a_i} \sum_k u_{i,j} \cdot x_{i,j,k} \right) \\
 & + \lambda_3 \min_{d_j} \left( r_j^+ + \sum_{a_i} \sum_k \hat{r}_i \cdot x_{i,j,k} \right) \\
 & + \lambda_4 \frac{\sum_{a_i \in A'} \sum_{d_j} \{v_j \cdot x_{i,j,0} + (1-v_j) \cdot x_{i,j,1}\}}{\sum_{a_i \in A'} \hat{y}_i} \\
 & + \lambda_5 \min_{c \in C} \left( \frac{\sum_{a_i} \sum_{d_j \in c} \sum_k \hat{r}_i \cdot x_{i,j,k}}{|c|} \right) \\
 \text{s.t.} \quad & \sum_{d_i} \sum_k x_{i,j,k} = 1 \quad (d_j \in D), \\
 & \sum_{d_j} x_{i,j,k} = R(\hat{y}_i \cdot \{(1-k) \cdot f_i + k \cdot (1-f_i)\}) \\
 & \quad (a_i \in A, k \in \{0, 1\}).
 \end{aligned}$$

目的関数について、第1項は地域効用の平均(目的2)、第2項は累積の地域効用の最小値(目的2)、第3項は累積の乗車数の最小値(目的2)、第4項は流し・待ち受け効用の平均(目的3)、第5項は企業の平均乗車数の最小値(目的3)を表している。最小値を最大化させることで格差が小さくなることが期待できる。また二つ目の制約条件の右項は、流しなら「割当空車数×流し割合」、待ち受けなら「割当空車数×待ち受け割合」を表しているものである。

以上の2段階にわたる最適化問題は、汎用の混合整数計画ソルバーを用いて現実的な計算時間で解くことが可能である。この最適化を実行することで、先述の目的をすべて達成することができる。混合整数計画問題はモデルの記述能力が高いため、現場の要請の応じて柔軟に制約条件や目的関数を変更することも可能である。そして、汎用の混合整数計画ソルバーを用いてすぐに求解できることは、実際の運用に当たって大きなメリットであると考えている。

## 4. 実データによる検証

令和元年度データ解析コンペティションにおいてみずほ情報総研株式会社から提供された都内タクシーのプローブデータを用いて、提案手法の有効性を確かめる。

表3 使用した特徴量

	変数	次元	A/T
基本データ	領域 ID	1	A
	クラスタの緯度経度	2	A
	駅数	1	A
	タクシーストップ数	1	A
	曜日・時間	6	T
	天気	16	T
	天気予報	4	T
時系列変化	鉄道人身事故	2	T
	fuzzy c-means	4	A
地域間移動	t-SNE	3	A
	node2vec	5	A

### 4.1 データと前処理

本研究の数値実験では、乗車数予測のための訓練データとして2017年4月の第1~3週を用いた。また、乗車数予測および配置最適化は、2017年4月第4週のデータを検証に用いた。対象地域は東京23区とし、分割した583地域について、15分間ごとの配置する空車の台数を決定する問題とする。ただし、起点は2017年4月1日の0時0分としている。

乗車数予測に用いた特徴量を表3に示す。表のうち次元の列は特徴を示す変数の数、A/Tと表記された列は、Aとあれば地域単位で設定される変数、Tとあればタイムステップ単位で設定される変数であることを表す。天気の16変数の内訳は東京都内の4カ所で記録された「降水量」「気温」「風速」「風向き」のデータとなる。また、鉄道人身事故については東京都内で「人身事故が起こったか否か」「人身事故のうち死亡事故が起こったか否か」という二つの変数となる。天気予報の内訳は前日に発表された東京の「0時~6時」「6時~12時」「12時~18時」「18時~24時」の予想降水量とした。また、乗車数の時系列変化に関する特徴量およびタクシーの地域間の移動情報に関する特徴量の生成には、2016年4月の第1~4週のデータを用いた。

### 4.2 乗車数予測および傾向スコア推定の検証

本節では3.1節で示した提案に関してその有効性を確かめる。

#### 4.2.1 傾向スコアの推定の有効性

最初に傾向スコアについて検証を行う。これは、特徴量Xから空車数eへのマッピングgがどれだけ正確か確かめることになる。われわれはこの非線形関数gの関数形として、表現力の高さから決定木を採用した。また、最適な決定木を求めるアルゴリズムには実装の平易さからLightGBM[18]を用いた。LightGBMは誤差が最小になるように決定木を逐次的に作成していく勾配ブースティング決定木(Gradient Boosting

表 4 傾向スコアの推定

	MPD	RMSE	R
過去平均	0.852	2.660	0.952
基本データ	0.354	1.841	0.966
基本データ + 時系列変化	0.346	1.821	<b>0.968</b>
全特徴量	<b>0.338</b>	<b>1.796</b>	<b>0.968</b>

Decision Tree, GBDT) アルゴリズムの一種で、特に LgithGBM は決定木の葉の枚数に制約をもつことや、並列計算することによって計算時間を削減しているなどの特徴がある。この方法が有効であることをベースラインと比較する。ベースラインは、該当時刻のちょうど 1 週間前、2 週間前、3 週間前に発生した 3 パターンの空車数の平均を出力するモデルとしている。

表 4 は傾向スコアの推定性能を表している。一行目の「過去平均」はベースライン、二行目以降は特徴量を増やしていったときの提案モデルである。三つの評価指標を使用して、推定性能を比較した。MPD は Mean Poisson Deviance [19] という指標を表し、テストラベルと予測ラベルにおけるポアソン分布の対数尤度の差を表す。また RMSE は平均平方二乗誤差、R は相関係数を表す。

この結果より、機械学習で傾向スコアを推定することによって、すべての指標がベースラインから改善していることが確かめられた。また、特徴量を段階的に増やしていくことで、傾向スコアの推定精度が向上していることがわかる。

#### 4.2.2 IPS による重み付けの有効性

次に、IPS によって誤差を重み付けすることの有効性を確かめる。乗車数予測の学習についても、表現力の高さと実装の平易さから LightGBM [18] を用いた。このため、経験誤差を用いた学習（以下 Naive 学習）と IPS 誤差を用いた学習（以下 IPS 学習）の比較を行う。評価指標は 3.1.2 節での議論を踏まえ、IPS 誤差を用いた評価（IPS 評価）を用いる。

まず、検証データにおける IPS 評価の結果が図 2 である。縦軸は IPS で重み付けされた平均二乗誤差に平方根をとり、台数のスケールに合わせた値となっている。横軸は右に行くほど段階的に特徴量が増えており、黒色が Naive 学習、白色が IPS 学習の結果を表す。この結果より、特徴量が多いときは Naive 学習よりも IPS 学習の方が誤差が小さくなっていることがわかる。これはすなわち、経験誤差を用いて学習してしまうと、配置最適化を行った場合に予測誤差が大きくなってしまふことを示している。

また、図 3 は、ある地域・時刻について空車数と

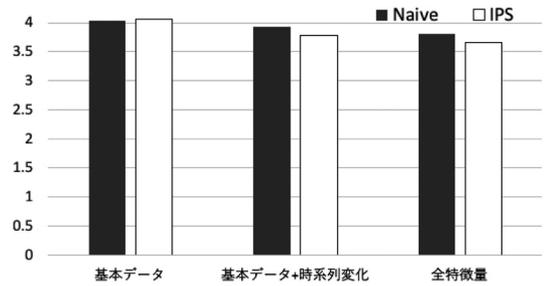


図 2 IPS 評価における Naive 学習と IPS 学習の結果

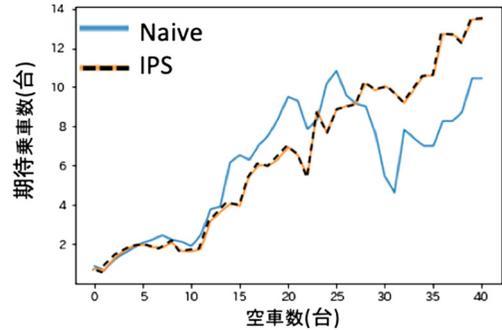


図 3 ある地域/時刻における空車数と乗車数の関係

乗車数の関係を計算した結果である。この図は実線が Naive 学習、破線が IPS 学習の結果を表しており、横軸が空車台数、縦軸が期待乗車数を表す。Naive 学習では、空車台数が 30 台のときよりも 20 台のときの方が期待乗車数が多いという不自然な結果となっている。それに対して、IPS 学習では極端に大きな空車台数でもおおよそ単調に乗車数が増加しており、自然な結果である。以上の結果より、配置最適化を前提とするのであれば IPS で学習することが有効であるといえる。

#### 4.3 配置最適化

最後に配置最適化の効果を検証する。ここでは、2017 年 4 月 25 日の 8:00-8:15、12:00-12:15、18:00-18:15 の三つのタイムステップで最適化し、各目的について評価を行った。ここで、ドライバー数はそれぞれのタイムステップで順に 1,372、2,515、2,647 であり、タクシー企業数はいずれも 7 であった。計算環境は、OS: Windows 10 Pro, CPU: Intel Core i7-8550U @ 1.80 GHz, メモリ: 16.0 GB である。また、混合整数計画ソルバーとして Gurobi の version 9.0.1 を用いた。

提案手法に対し、「資源配分問題として解く方法」と「割当問題として解く方法」の 2 種類をベースモデルとして比較する。前者は、3.2.2 節で提案した乗車数最大

表 5 配置最適化の実行結果

時刻	手法	期待乗車数	平均地域効用	最小累積地域効用	最小累積乗車数	企業間格差
8:00-8:15	資源配分問題	<b>1624</b>	1.003	0.138	0.393	25.74%
	割当問題	982	<b>1.684</b>	<b>0.991</b>	0.275	3.43%
	2 段階 (提案手法)	<b>1624</b>	1.526	0.446	<b>0.433</b>	<b>1.06%</b>
12:00-12:15	資源配分問題	<b>1995</b>	1.000	0.109	0.150	21.35%
	割当問題	1281	<b>1.637</b>	<b>0.940</b>	0.252	<b>3.45%</b>
	2 段階 (提案手法)	<b>1995</b>	1.419	0.368	<b>0.332</b>	4.90%
18:00-18:15	資源配分問題	<b>3366</b>	0.990	0.139	0.328	14.63%
	割当問題	2378	<b>1.720</b>	<b>1.111</b>	0.235	0.93%
	2 段階 (提案手法)	<b>3366</b>	1.692	0.901	<b>0.457</b>	<b>0.74%</b>

化から算出された各地域の空車タクシー数を満たすように、各空車タクシーについて地域と状態をランダムに決定する方法である。後者は、ランダムに各地域に配置する空車タクシー数を決定した後、3.2.3 節で提案したドライバーの労働環境や実用性を改善させるように、各空車タクシーについて地域と状態を最適に割り当てる方法である。

パラメータおよび定数、その他状況について次のように設定した。まず 1 段階目のパラメータについては、 $e_{max} = 40$ 、 $\lambda = 0.000001$ 、 $p_{min} = 0.001$ 、 $l_{max} = 0.018$  (約 1.8km) とした。ただし地域間の距離は、地域の代表地 (ポロノイ領域の母点) 間における緯度と経度の 2 軸によるユークリッド距離として定義している。次に 2 段階目のパラメータについては、 $\lambda_1 = 1$ 、 $\lambda_2 = 1$ 、 $\lambda_3 = 2$ 、 $\lambda_4 = 2$ 、 $\lambda_5 = 1$  とした。また、今回の数値実験の範疇では実在するドライバーの真の地域効用や流し効用を得ることは困難であるため、乱数による決定で代用した。 $u_{i,j}$  は各ドライバーごとに各地域への効用が平均 1 になるように割り当て、 $u_j^+$ 、 $v_j$  は各ドライバーごとにそれぞれ区間  $[0, 10]$ 、区間  $[0, 1]$  の一様分布から得られる値を割り当てた。最後に流し・待ち受けを決定する  $\mathcal{A}'$  および  $f_i$  について、 $\mathcal{A}'$  は 1 段階目で空車タクシーを 15 台以上配置する地域の集合とし、 $f_i$  は区間  $[0, 1]$  の一様乱数から得られる値を割り当てた。今回の数値実験において乱数で設定した値は、実用の際には経験知や情報をもって決定することができる。

配置最適化の計算を各時刻・各手法でそれぞれ 40 回ずつ行い、その平均値を比較する。ただし、乱数で決定する定数や状況に関しては、各回ごとに設定し直す。

表 5 は、それぞれのタイムステップにおける配置最適化の実行結果である。「期待乗車数」は、配置最適化 1 段階目の目的関数の第 1 項である。次に「平均地域効用」、「最小累積地域効用」、「最小累積乗車数」はそれぞれ、配置最適化 2 段階目の目的関数の第 1, 2, 3 項である (係数は除いている)。最後に「企業間格差」は、

企業ごとの 1 台あたり平均期待乗車数について、「(最大 - 最小)/最大」を計算したものである。この結果から、資源配分問題と割当問題のトレードオフが確認できる。また、提案手法は両者の長所を兼ね備えた結果となっており、配置最適化の目的すべてを達成できていることが示された。さらに提案手法の計算時間は台数が最も多い 18:00-18:15 のタイムステップにおいて平均 45.6 秒 (40 回の試行) であり、実用性を確認できた。

## 5. おわりに

本研究は都内タクシーのプロープデータを用いて乗車数予測を行い、その予測結果を用いて空車タクシーを最適に配置する手法を提案した。乗車数予測と配置最適化を組み合わせることによって、①全体の乗車数の最大化、②個別の労働環境の維持・改善、③実用性の確保という三つの目的を果たした。

提案手法である乗車数予測モデルは、反実仮想機械学習を用いることにより、空車数の変化に対応して乗車数予測ができるという特徴をもつ。そのため、タクシーの空車数が大きく変化する状況 (大規模な道路工事やタクシー乗り場の新設など) に対する What-If 分析などにも応用可能だと考える。

今後の課題が二つ挙げられる。一つ目は、乗車数予測モデルに直近の時刻の予測・実測情報を組み込むことである。本提案手法は空車数の変化に対する乗車数の予測精度を向上させたが、突発的な需要の増加 (花火大会による混雑など) には対応しきれない可能性がある。そこで直近の時刻の予測・実測情報を組み込むことで突発的な需要の変化にも対応した予測モデルが可能であると考えられる。二つ目は、空車数の増加に対して乗車数の予測値を単調非減少にすることである。図 3 は本提案手法によって空車タクシー数の増加と共におよそ単調非減少となる予測となっているが完全ではない。出力結果に対しスムージングを行うことや、空車数に対して乗車数が単調非減少性を満たすように設計した予測モデルを用いることが考えられる。

謝辞 都内タクシーのプローブデータを提供いただきました、みずほ情報総研株式会社およびデータ解析コンペティション運営の皆様にご礼申し上げます。また、丁寧な査読および大変有意義なコメントをいただきました匿名の審査員のお二人にご礼申し上げます。

#### 参考文献

- [1] 後藤孝夫, “大都市におけるタクシー事業の経営と規制政策,” 福岡大学商学論叢, **60**, pp. 85–104, 2015.
- [2] D. B. Rubin, “Estimating causal effects of treatments in randomized and nonrandomized studies,” *Journal of Educational Psychology*, **66**, p. 688, 1974.
- [3] H. Yao, F. Wu, J. Ke, X. Tang, Y. Jia, S. Lu, P. Gong, J. Ye and Z. Li, “Deep multi-view spatial-temporal network for taxi demand prediction,” In *Proceeding of the 2018 AAAI Conference on Artificial Intelligence (AAAI’18)*, p. 2588, 2018.
- [4] A. Afian, A. Odoni and D. Rus, “Inferring unmet demand from taxi probe data,” In *Proceeding of the 2015 IEEE 18th International Conference on Intelligent Transportation Systems*, pp. 861–868, 2015.
- [5] T. Schnabel, A. Swaminathan, A. Singh, N. Chandak and T. Joachims, “Recommendations as treatments: Debiasing learning and evaluation,” In *ICML’16 Proceedings of the 33rd International Conference on International Conference on Machine Learning*, **48**, pp. 1670–1679, 2016.
- [6] T. Joachims, A. Swaminathan and T. Schnabel, “Unbiased learning-to-rank with biased feedback,” In *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, pp. 781–789, 2017.
- [7] A. Swaminathan and T. Joachims, “Counterfactual risk minimization: Learning from logged bandit feedback,” In *Proceeding of the International Conference on Machine Learning*, pp. 814–823, 2015.
- [8] C. Yan, H. Zhu, N. Korolko and D. Woodard, “Dynamic pricing and matching in ride: Hailing platforms,” *Naval Research Logistics*, **67**, pp. 705–724, 2019.
- [9] R. Iglesias, F. Rossi, K. Wang, D. Hallac, J. Leskovec and M. Pavone, “Data-driven model predictive control of autonomous mobility-on-demand systems,” In *Proceeding of the 2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 1–7, 2018.
- [10] 西智樹, 小出智士, 大滝啓介, 大社綾乃, “オンデマンド交通システムのための階層的車両配置最適化,” 人工知能学会全国大会論文集, pp. 4Rin120–4Rin120, 2019.
- [11] 伊藤彰彦, “地域メッシュ統計の紹介,” 行動計量学, **4**, pp. 59–63, 1976.
- [12] T. Zhang, R. Ramakrishnan and M. Livny, “Birch: An efficient data clustering method for very large databases,” *ACM SIGMOD Record*, **25**, pp. 103–114, 1996.
- [13] R. L. Cannon, J. V. Dave and J. C. Bezdek, “Efficient implementation of the fuzzy c-means clustering algorithms,” *IEEE transactions on pattern analysis and machine intelligence*, PAM1-8, pp. 248–255, 1986.
- [14] L. van der Maaten and G. Hinton, “Visualizing data using t-SNE,” *Journal of Machine Learning Research*, **9**, pp. 2579–2605, 2008.
- [15] A. Grover and J. Leskovec, “node2vec: Scalable feature learning for networks,” In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 855–864, 2016.
- [16] D. Liang, L. Charlin and D. M. Blei, “Causal inference for recommendation,” In *Causation: Foundation to Application, Workshop at UAI.*, 2016.
- [17] N. Kallus and A. Zhou, “Policy evaluation and optimization with continuous treatments,” In *Proceedings of the 21st International Conference on Artificial Intelligence and Statistics (AISTATS)*, 2018.
- [18] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye and T.-Y. Liu, “Lightgbm: A highly efficient gradient boosting decision tree,” In *Advances in Neural Information Processing Systems*, pp. 3146–3154, 2017.
- [19] P. C. Consul and F. Famoye, “Generalized poisson regression model,” *Communications in Statistics-Theory and Methods*, **21**, pp. 89–109, 1992.