

# 辺ベクトルを用いた経路推薦問題の解法における 目的関数の改善に関する提案

## Proposal to Improve Objective Function for Route Recommendation Problem Using Edge Vector-based Formulation

柴田祐樹<sup>1</sup> 高間康史<sup>1\*</sup>  
Hiroki Shibata<sup>1</sup> Yasufumi Takama<sup>1</sup>

<sup>1</sup> 首都大学東京大学院システムデザイン研究科

<sup>1</sup> Graduate School of System Design, Tokyo Metropolitan University

**Abstract:** This paper proposes to improve the objective function used for the route recommendation problem using the Edge Vector-based formulation. In this formulation, there are real and virtual edges. Real edges represent the routes of a given problem, and virtual edges are used to transform a non-complete graph like a real world road map into a complete graph. However, the effects of real and virtual edges to the objective function are not symmetric, which decreases the performance of the optimization when a state variable includes virtual edges. This paper shows an alternative formulation of the objective function that satisfies the symmetry on the effect of real and virtual edges. The effectiveness of the proposed method is shown by the experiments on a real world data set and an artificial data set.

### 1 はじめに

観光旅行をする際、ガイドブックや旅行会社が提供する観光ツアーを利用するのではなく、Social Networking Service (SNS) などの Web から入手した情報を用いて旅行者自身で観光計画を立案することも増えてきている。観光情報サイトなどでは、エリアなどの指定条件を満たす観光スポットをランキング形式で提示するサービスを提供しているが、知名度の高いスポットや宣伝に力を入れているスポットが上位に表示される傾向がある。ユーザの検索行動として、ランキング上位の数件のみしか確認しないことが一般的であるため、結果として個人の趣味嗜好に合った観光地を訪れる機会の損失を招き、一部の観光地へ旅行客が集中するなど、旅行客、観光地側双方に不利益を生じる。こういった問題を防ぐためにも、ユーザの好みに応じたスポットを選び、限られた時間で効率よく巡回する経路を提案する観光経路推薦手法は重要であり、研究が進められている [1][2][3]。

与えられた節点全てを巡回する最短経路を求める問題は Traveling Salesman Problem (TSP) [4] として古くから研究されている。NP-Hard [5] に属する TSP を解くためには近似解法が用いられ、代表的なものには

2-Optimization (2-Opt) 法 [6]、Simulated Annealing (SA) [7] がある。さらに、スポットに価値を付加し、与えられた総負荷制限の中で価値の総和が最大となる経路を選ぶ問題として、Selective Traveling Salesman Problem (STSP) [8] が定式化されている。文献 [1]、[3] では STSP に基づく問題の定式化において、スポットの価値を Web から取得したデータを用いて推定する方法を提案している。また、文献 [2] は STSP を拡張し、訪れた時間に依存して価値が変化する問題を最適観光経路問題として定式化することを提案している。

以上のように、TSP および STSP を拡張した定式化は広く用いられているが、STSP では節点にスポットを割当て、節点間の辺の重みに、スポット間を結ぶ最短経路等の固定的な負荷 (コスト) を割り当てるため、特定の交通機関や道路しか用いられないことに等しい。これにより、途中経路選択に対するユーザの価値観を考慮できず、また、ユーザの集中による混雑の発生等の問題も考えられ、Web から得られるデータが潤沢となっている近年の状況において適切なモデル化であるとは言えない。これに対し文献 [9] ではスポットのみでなく、途中の経路における街並みや景観等もユーザにとって重要な因子であるとし、これらを考慮可能な観光経路推薦手法 (以降 Edge Vector: EV と呼ぶ) を提案している。スポットおよび経路に関する価値や負荷すべてを辺に対する重みとして定式化することで、ス

\*連絡先: 首都大学東京大学院システムデザイン研究科  
〒191-0065 東京都日野市旭が丘 6-6  
E-mail: ytakama@tmu.ac.jp

ポットと経路の情報を統一的に扱い、最適化の過程において両者を同時に調整しながら最適経路の発見を可能としている。

EV において、最適化手法として SA が用いられる。最適化の過程では問題を構成する経路に対応しない辺 (仮想辺) が用いられ、仮想辺が実際の経路に対応する辺 (実辺) に置換されるように目的関数を定式化することで非完全グラフに対応しつつ、実辺上のスポットを探索可能としている。しかしながら、目的関数に対する実辺・仮想辺の影響が対称でないことが置換の過程に影響し、最適化効率の低下が予測されるため、対称性が最適化に及ぼす影響の調査、およびそれに基づいた定式化の改良を行う必要があると考える。

以上の背景のもと、本稿では、対称性が最適化に与える影響を数学的に考察し、対称性の低い定式化では最適化効率が低下する場合があることを示す。この問題に対し、実辺・仮想辺について対称性の高い目的関数の定式化を提案し、最適化効率を改善できることを示す。人工データセットおよび文献 [1] で用いられているテーマパークにおける観光客の行動履歴から作成されたデータセットを用いた評価実験により、提案する定式化の有効性を示す。

## 2 関連研究

### 2.1 STSP に基づく経路推薦

TSP には全ての節点を一度ずつ訪れるという制約があるため、スポットに対して取捨選択性のある観光経路推薦問題にこの定式化をそのまま適用することはできない。既存研究では、訪れる節点に関する制約の代わりに、通過する経路の負荷の合計 (総所要時間等) に対して制約を設け、スポットに設定された価値の総和を最大化する問題である STSP [8] の定式化を利用、あるいは拡張したのことが多い [1][2][3]。

文献 [1] では、待ち時間が頻繁に発生するテーマパークにおける経路推薦手法を提案している。アトラクションを節点 (その集合を  $\mathcal{N}$  とする)、巡回する節点の総数を  $D$  として、推薦する経路を節点の列  $n = (n_i \in \mathcal{N} | i = 1, \dots, D)$ 、各節点を訪れた時刻を  $t = (t_i \in \mathbb{R} | i = 1, \dots, D)$  と表現している。  $n_1, n_D$  はそれぞれ固定的な始点、終点であり、最適化の過程で変化することはないが、巡回する節点の総数  $D$  は最適化の過程で変化する。  $U$  をユーザの集合とし、各アトラクションにはユーザごとに異なる価値 (好み)  $f_{\text{int}} : U \times \mathcal{N} \rightarrow [0, \infty)$ 、全ユーザで共通の人気度  $f_{\text{pop}} : \mathcal{N} \rightarrow [0, \infty)$ 、ある時刻における待ち時間  $t_{\text{queue}} : \mathcal{N} \times \mathbb{R} \rightarrow [0, \infty)$ 、アトラクションの所要時間 (待ち時間を除く)  $t_{\text{dur}} : \mathcal{N} \rightarrow [0, \infty)$  が定義され

る。また、全てのアトラクション間について、移動時間  $f_c : \mathcal{N}^2 \rightarrow [0, \infty)$  が定義されている。以上の設定において、ユーザ  $u \in U$  に対してテーマパーク内のアトラクションを巡る最適な経路を推薦する問題を、式 (1) で与えられる所要時間  $C_c \in [0, \infty)$  の制約のもと、式 (2) に定義される目的関数  $F$  を最大化する  $n$  を求める問題と定式化している<sup>1</sup>。

$$\sum_{i=1}^D \{f_c(n_i, n_{i+1}) + t_{\text{dur}}(n_i) + t_{\text{queue}}(n_i, t_i)\} < C_c \quad (1)$$

$$F = \sum_{i=1}^D \left( \frac{f_{\text{int}}(u, n_i) + f_{\text{pop}}(n_i)}{t_{\text{queue}}(n_i, t_i)} \right) \quad (2)$$

解法としては Monte Carlo Tree Search [10] を拡張した PersQ と呼ばれる手法が提案されている。STSP では式 (1) の制約の他に、各スポットを訪れる回数が一度以下である制約、始点と終点を必ず訪れる制約、経路が繋がっている制約を満たす必要があるが、PersQ はこれらを満たす解のみを探索するように実装されている。

文献 [2] では、STSP をスポットにおける価値の時間的変化も考慮するように拡張した定式化を提案している。文献 [3] は、ユーザと対話的に経路を決定していく支援システムである CTPlanner を提案している。問題の定式化には STSP を用い、辺の重みには Google Map 等の経路案内サービスを用いてあらかじめ算出した値を移動負荷として設定している。解法には遺伝的アルゴリズム [11] を用いている。

### 2.2 辺ベクトルを用いた観光経路推薦手法の定式化

本節では EV の定式化と、同手法で用いられる近似解法について述べる。また、各用語の命名が文献 [9] において曖昧であると考えられるものについては、対応関係を示しながら、本稿で新たに定義したものをを用いて説明する。

$\mathcal{N}$  を節点の集合、 $\mathcal{E}_p$  を辺の全体集合とする。 $\mathcal{E}_p$  は問題に与えられた辺 (定義辺) と後述する自己回帰辺、仮想辺<sup>2</sup>を含む。辺  $e \in \mathcal{E}_p$  に対し、 $n_{\text{st}}(e)$  を  $e$  の始点、 $n_{\text{ed}}(e)$  を  $e$  の終点としたとき、これらは  $\bigcup_{e \in \mathcal{E}_p} (n_{\text{st}}(e), n_{\text{ed}}(e)) = \mathcal{N}^2$  の関係を満たすものとする。

$|\mathcal{N}|$  個の辺からなる経路を含む辺ベクトルを  $\mathbf{e} := (e_i | i = 1, 2, \dots, |\mathcal{N}|)$  と定義する。 $n_{\text{st}}(e_1)$  は経路の始

<sup>1</sup>式 (1) と式 (2) による問題の定義は文献 [1] に書かれているものと多少異なるが、説明を簡潔にするため最低限必要な条件のみを満たすように記述している。

<sup>2</sup>文献 [9] では実在辺、自己ループ辺、非存在辺と呼ばれる






図 3: 制約関数の概形. STSP: STSP, EV: 文献 [9].




図 4:  $\sigma^2 = 1, \alpha_g \in \{1.0, 0.2, -0.2, -1.0\}$  における  $F_{\text{res}}(x)$  のグラフ.

を消滅させるための罰則係数に対応するものであり、1 以上で、かつ仮想辺が最終的に問題なく消滅する程度に 1 に近い値を用いる。

$F_{\text{res}}: \mathbb{R} \rightarrow \mathbb{R}$  は経路負荷に対する STSP の制約を表現する関数であり、 $C_c$  は制約値である。観光経路推薦においてこの制約値は、経路長や旅行時間に対応する。STSP, EV における制約関数の概形を図 3 に示す。STSP では経路長が  $C_c$  を超えることを認めないため、目的関数は  $C_c$  を堺に無限大の値を取る。このような目的関数を用いた最適化では、経路長が  $C_c$  付近となる状態の近傍探索における最適化効率が低下する。また、興味のあるスポットがあれば、多少の制約違反が許容される観光旅行においてこのモデル化は妥当であるとは言えない。これに対し、EV ではある程度の誤差を認め、最適化効率を向上させたいうで、より現実的なモデルとしている。

EV と 3 節で説明する提案手法で共通して利用する制約関数の定式化を式 (6) に示す。

$$F_{\text{res}}(x) = \begin{cases} \alpha_g x + c_1 & , x < x_m \\ c_2 x^2 + c_3 x & , x_m \leq x \leq \sigma^2 \\ x + c_4 & , \sigma^2 < x \end{cases} \quad (6)$$

各設定値を、 $c_1 = c_2 x_m^2 + c_3 x_m - \alpha_g x_m$ ,  $c_2 = (1 - c_3)/(2\sigma^2)$ ,  $c_3 = \max(\alpha_g, 0)$ ,  $x_m = (\alpha_g - c_3)/(2c_2)$ ,  $c_4 = c_2(\sigma^2)^2 + c_3\sigma^2 - \sigma^2$  と定めたとき、 $\alpha_g = -1$  において、この関数は EV のものに対応する。 $\sigma^2$  は制約違反の許容量を決定するパラメータであり、これにより違反の許容度合いを調節することが可能である。図 4

に  $\alpha_g$  の値による  $F_{\text{res}}$  の形状の違いを示す。

SA において、Boltzmann 分布を近似するために Gibbs Sampling (GS) [13] を用いる。経路変更を行うための最小要素は二つの辺であるため、GS において利用される部分空間として辺ベクトル中の 2 辺を選ぶ。この 2 辺に対する添字を  $i, j (\in A)$  としたとき、これら以外の添字  $A \setminus \{i, j\}$  で定義される変数により条件付けられた分布は式 (7) と書ける。

$$p(\mathbf{e}_{\{i,j\}} | \mathbf{e}_{A \setminus \{i,j\}}) = \frac{\exp(-\frac{1}{kT} \phi(\mathbf{e}_A))}{\sum_{\mathbf{y}_{\{i,j\}}} \exp(-\frac{1}{kT} \phi(\mathbf{y}_{\{i,j\}}, \mathbf{e}_{A \setminus \{i,j\}}))} \quad (7)$$

添字  $A$  の部分集合  $M$  を添え字に持つ確率変数は対応する部分空間を構成し、式 (8) の性質が満たされる [14]。

$$p(\mathbf{e}_{A \setminus M}) = \sum_{\mathbf{y}_M} p(\mathbf{y}_M, \mathbf{e}_{A \setminus M}), M \subset A \quad (8)$$

ここで、 $\sum_{\mathbf{y}_M}$  は  $\mathbf{y}_M$  の状態空間についての総和を示す。この状態空間には 2-Opt 法に対応する、経路としての制約を満たすものを与える。

操作対象となる 2 辺の添字集合  $\{i, j\}$  は状態変化が起こらないような無駄な GS の試行を削減するように選ばれる。EV ではこの選択法による GS の適用法を近似的な棄却サンプリングと呼んでいる。この選択法では目的関数の変化量を近似的に見積もり、予測される変化量の小さい方から  $K$  番目以内までの状態への変化を与えるものの中から  $\{i, j\}$  を無作為に選択する。SA の基礎となる Markov Chain Monte Carlo 法の枠組みにおいては、提案分布 [16] による探索範囲を近傍の状態に制限する方法と見る方が適切であるため、本稿ではこの手法を近傍探索法と呼ぶ。

### 3 対称性に対する考察と提案手法

式 (4) 中のパラメータについて、EV では  $\alpha_s = 0, \alpha_{as} \approx 1 \wedge \alpha_{as} > 1$  としており、仮想辺の負荷  $f_s$  は制約関数  $F_{\text{res}}$  に含まれないため、仮想辺と対応する実辺の入れ替えに対して目的関数の値が大きく変化する。仮想辺と実辺に関して非対称な定式化となっている。

非対称性が最適化に及ぼす影響について、以下により定義される  $F_c(\mathbf{e}_A), F_s(\mathbf{e}_A)$  を用い、次のように考察を行う。

$$F_s(\mathbf{e}_A) = \sum_{i \in A} f_s(\mathbf{e}_i)$$

$$F_c(\mathbf{e}_A) = \sum_{i \in A} f_c(\mathbf{e}_i)$$

ある状態  $e_A$  からの  $\phi(e_A)$  の変化量を  $\Delta\phi$ ,  $F_s(e_A)$  の変化量を  $\Delta F_s$ ,  $F_c(e_A)$  の変化量を  $\Delta F_c$  と表し、経路の様々な遷移過程について、仮想辺を対応する実辺集合に置換したとき、およびその逆の置換を行ったときの  $\Delta\phi$  について考える。式 (4) から、 $\Delta\phi$  を式 (9) で近似する。

$$\Delta\phi = \xi\Delta F_c + \alpha_s\xi\Delta F_s + \alpha_{as}\Delta F_s \quad (9)$$

$\xi = F'_{res}(F_c(e_A) + \alpha_s F_s(e_A) - C_c)$  としている。なお、 $f_d$  は STSP の制約に関係なく、 $F_{res}$  に含まれないため、負荷の対称性に関する本議論においては考慮に入れない。ここで、 $e_A$  に、仮想辺  $e^v \notin \mathcal{E}$  を足したことによる  $\phi$  の変化量を  $\Delta\phi^{+v}$ 、対応する実辺上の最短経路である  $S(e^v)$  ( $\subset \mathcal{E}$ ) を足したことによる変化量を  $\Delta\phi^{+s}$  とする。 $\Delta\phi^{+v}, \Delta\phi^{+s}$  は式 (5) による  $f_s$  の定義と式 (9) を用いれば、それぞれ式 (10)、式 (11) と書ける。

$$\Delta\phi^{+v} = \alpha_s \xi f_s(e^v) + \alpha_{as} f_s(e^v) \quad (10)$$

$$\Delta\phi^{+s} = \xi f_s(e^v) \quad (11)$$

以上の結果より、 $\alpha_s \approx 0, \alpha_{as} \approx 1$  と設定する EV の定式化では、 $F_c(e_A) \geq \sigma^2$  において  $\xi = 1$  となるため、 $\Delta\phi^{+v}$  と  $\Delta\phi^{+s}$  はほぼ等しいが、 $F_c(e_A) < \sigma^2$  においては  $F_c(e_A)$  の値が小さくなるほど差異が大きくなるのがわかる。つまり、このような定式化を用いた探索においては、仮想辺と対応する実辺の入れ替えに関して目的関数の値が大きく変化するため、GS における状態変化の過程は、2 辺以上の同時操作により実辺のみを用いた探索と、仮想辺を経由した場合で大きく異なることとなり、最適化効率の低下が予測される。

この問題に対し、本稿では仮想辺を実辺と対称に扱う、 $\alpha_s = 1, \alpha_{as} \approx +0$  の設定を用いることで最適化効率を改善する目的関数の定式化を提案する。この設定においては、式 (10)、式 (11) より、 $\xi$  の値に関係なく  $\Delta\phi^{+v}$  と  $\Delta\phi^{+s}$  がほぼ等しくなるのがわかる。この場合、仮想辺と対応する実辺の入れ替えに関して目的関数の値がほぼ変化しないため、仮想辺を経由した場合における最適化効率の低下が起きないと考える。

完全に対称性を満たすとき、置換に関して目的関数の値が変化しなくなり、仮想辺の実辺への置換が起きづらくなる。つまり、定義辺上のスポットの探索が行われにくくなるため、僅かに対称性を崩すために、 $\alpha_{as}$  に微小な値を設定する。この値の設定方法に、ユーザ毎に値が異なる  $f_d$  は関与しないため、問題のグラフに対して事前実験を行うことにより、全てのユーザに対して利用可能な共通の値を定めることができる。

対称性が満たされることが最適化の結果に及ぼす具体的な影響を考察する。辺ベクトルの状態は、Random Walk [16] と同様の性質により温度が高いときには経




図 5: 5 × 3 の節点からなる升目構造グラフの人工データセット。四角は始点、三角は終点をそれぞれ表す。

路長が長い状態を取り、そこから温度が下がるにつれ、仮想辺を含む状態と、対応する実辺に置換された状態を交互に取りながら短い経路に遷移していくが、上述の通り、EV の定式化に対応する  $\alpha_s \approx 0, \alpha_{as} \approx 1$  とするとき、仮想辺を含む状態への変化が起こりづらくなる場合があるため、経路は長い状態のまま硬直する可能性がある。その結果、最終的な経路長が長くなりやすいと考えられる。この問題が実際に起こり、対称性の高い定式化において解決できることは 4 節の評価実験により示す。

対称性の議論からは外れるが、 $\alpha_g$  の設定次第で最適化効率の向上を望めるため、このパラメータの設定方法についても述べる。 $\alpha_g$  を大きくするほど、 $F_{res}(x)$  は単調な直線に近くなり STSP の制約が機能しづらくなるため、 $\alpha_g$  には小さな値を用いることが望ましい。また、 $\alpha_g \approx 0$  とすることで、対称性が満たされる条件、つまり、 $\alpha_s = 1$  ならば  $F_c(e_A) + F_s(e_A) < C_c$  である状態  $e_A$  について  $\phi(e_A)$  は  $F_c(e_A), F_s(e_A)$  によらず一定となり、そのような経路間を滑らかに探索できるため、計算精度の向上が期待できる。また、 $\alpha_g > 0$  の設定では、経路長に対して目的関数は常に正の傾きを持つため、より短い経路長を持つ状態ほど目的関数の値が小さくなる。このことから、 $\alpha_g \approx 0 \wedge \alpha_g > 0$  と設定することで、無駄な経路を削減可能な、かつ精度の高い探索となることが期待できる。

## 4 評価実験

### 4.1 人工データセットによる実験

3 節の考察で予想したとおり、既存手法では生成される辺ベクトルを  $e_A^*$  としたとき、その経路の長さ  $F_c(e_A^*)$  が  $C_c$  よりも長くなりやすいことと、提案する定式化を用いた場合にこれを解決できることを検証するため、図 5 に示すような升目構造を持つ人工データセットを用いた実験を行った。図において、四角、三角はそれぞれ始点、終点を表す。実験では 20 × 20 のサイズを用いたが、スペースの関係上図では 5 × 3 としている。また、 $\forall e \in \mathcal{E}, f_c(e) = 1 \wedge f_d(e) = 0$  としている。



表 1: 様々な  $(\alpha_g, \alpha_s)$  において提案する定式化を用い生成された辺ベクトル  $e_A^*$  の経路長  $F_c(e_A^*)$  と計算時間の平均値.

$(\alpha_g, \alpha_s)$	平均経路長	平均計算時間 [s]
$(-1, 0)$	106.9	10.2
$(-1, 1)$	100.0	5.42
$(0.01, 0)$	106.7	9.96
$(0.01, 1)$	1.000	2.80

$(\alpha_g, \alpha_s) \in \{(-1, 0), (-1, 1), (0.01, 0), (0.01, 1)\}$  における,  $C_c = 100, \sigma^2 = 50$  とした場合の, 128 回の試行における  $F_c(e_A^*)$  の平均値と, 計算時間<sup>4</sup> の平均値を表 1 に示す.  $t \in [0, 1]$  を,  $t = 0$  が計算開始,  $t = 1$  が計算終了を意味する計算の進行度としたとき, 温度変化は  $T(t) = 10^{-3t}$  により与え,  $t$  が  $5 \times 10^{-5}$  進む毎に標本抽出を行い,  $\alpha_{as} = 0.005$ , Boltzmann 定数には文献 [9] の指針に従い  $k = 1.2$  を選び, 近傍探索の範囲には  $K = 16$  を用いた. 擬似乱数の生成には Mersenne Twister [17] を用いた.

表 1 より, 文献 [9] の定式化に対応する  $(\alpha_g, \alpha_s) = (-1, 0)$  では 3 節での議論の通り,  $C_c$  の値より長い経路が生成される傾向にあることがわかる.  $(\alpha_g, \alpha_s) = (0.01, 0)$  の場合でもこの傾向は変わらないことから, 目的関数を経路長に対して単調増加とただけではこの傾向は改善されないことがわかる. 一方, 3 節での議論に従い  $\alpha_s = 1$  とした  $(\alpha_g, \alpha_s) = (-1, 1)$  のときはほぼ期待される経路長が得られていることがわかる. また,  $(\alpha_g, \alpha_s) = (0.01, 1)$  の実験結果では始点・終点を直接結ぶ長さ 1 の経路が生成される傾向にあることがわかる. 本実験では  $\forall e \in \mathcal{E}, f_d(e) = 0$  としており, 経路長を増加させるメリットがないため妥当な結果といえる. これらの結果から,  $\alpha_s = 1$  とする対称性の高い設定において, 目的関数の形状から期待される解を得られることがわかる. また, 生成される経路長が短いほど計算時間が減少しており, 無駄な経路を削減する  $\alpha_g$  の設定と合わせれば, 提案する定式化は高速化にも貢献することがわかる.

## 4.2 実データセットによる実験

文献 [9] における評価実験と同様に, 文献 [1] で用いられているデータセットを用いて実験を行った. 評価指標には文献 [9] と同様, Recall を用いる. 既存手法および

<sup>4</sup>C++ 14 で実装し, Ubuntu 16.04.5 上において, g++ version 5.4.0 により最適化オプション `-O3` を付加してコンパイルし, 同 OS 上で倍精度浮動小数点数を用いて計算した結果に基づく. 個々の実験はすべて単一スレッドにより実行され, CPU には Ryzen Thread Ripper 1920X (<https://www.amd.com>) を用い, 主記憶は DDR4-2400 をバス幅 256 bit で接続し動作させた.

表 2: PersQ[1] と提案する定式化 ( $EV(\alpha_g, \alpha_s)$ ) を用いた結果の Recall.  $EV(-1, 0)$  が文献 [9] の定式化におけるものに対応する. C: Cali. Adv, H: Hollywood, D: Disneyland M: Magic King., E: Epcot.

	C	H	D	M	E
PersQ	<b>0.483</b>	<b>0.482</b>	0.332	0.440	0.472
$EV(-1, 0)$	0.291	0.421	0.231	0.388	0.401
$EV(0.01, 0)$	0.406	0.461	0.405	0.450	0.530
$EV(0.01, 1)$	0.441	0.472	<b>0.423</b>	<b>0.475</b>	<b>0.555</b>

提案手法により生成された経路の Recall を表 2 に示す. PersQ は文献 [1] で提案された手法,  $EV(\alpha_g, \alpha_s)$  が提案する定式化である.  $EV(-1, 0)$  が文献 [9] における定式化に対応する.  $EV(-1, 0)$  においては,  $\alpha_{as} = 1.005$  を, それ以外の設定においては  $\alpha_{as} = 0.005$  を用いた. 温度変化は  $T(t) = 10^{-4t}$  に従うとし,  $t$  が  $5 \times 10^{-4}$  進む毎に標本抽出を行った. 擬似乱数の生成には 4.1 節における実験と同様に Mersenne Twister を用いた. その他の設定値については文献 [9] と同様である.

表 2 から, 提案する定式化を用いることで性能が向上することを確認できる.  $\alpha_s = 1$  とする対称性の高い設定において精度が向上していることがわかるが, 特にこのデータセットでは,  $\alpha_g$  の調整が性能改善に貢献していることがわかる.

## 5 おわりに

本稿では, 辺ベクトルによる定式化を用いた経路推薦手法において, 実辺と仮想辺の対称性が最適化効率に与える影響を数学的に考察し, 高い対称性を持つ設定が可能な目的関数の定式化を提案した. 評価実験により, 考察から予測される最適化効率の低下が再現されることを示し, 提案する定式化において対称性の高い設定とした場合にこの問題を解決できることを示した. また, 提案する定式化を用いることで, 実データセットを用いた評価実験では既存の定式化を用いたものを上回る性能を達成可能なことを示した. 今後, 実際の道路ネットワークにおける検証を行うことで, より現実に即した解法とすることが期待できる. また, 本手法は確率的生成モデルとして定式化されているため, 同モデルに対する学習則を利用しスポットの価値を推定できる可能性がある. 確率的生成モデルにおいて推論と学習に利用する手法は本質的に同じであり, 価値の推定と推論を同一のアルゴリズムにより実装できれば理論的解析も行いやすくなると考えるため, 検討する予定である.

## 謝辞

本研究の一部は JSPS 科研費 16K12535, 15H02780 の助成および首都大学東京傾斜的研究費 (全学分) 学長裁量枠戦略的研究プロジェクト戦略的研究支援枠「ソーシャルビッグデータの分析・応用のための学術基盤の研究」によるものです。

## 参考文献

- [1] Lim, K., Chan, J., Karunasekera, S.: Personalized Itinerary Recommendation with Queuing Time Awareness, *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 325-334 (2017)
- [2] 松田善臣, 名嘉村盛和, 姜 東植, 宮城 隼夫: 最適観光経路問題とその解法, 電気学会論文誌 C, Vol. 124, No. 7, pp. 1507-1514 (2004)
- [3] 倉田陽平, 有馬貴之: 対話的旅行計画作成支援システムの実装と評価, 第 25 回日本観光研究学会全国大会, pp. 173-176 (2010)
- [4] Gutin, G., Punnen, A.: The Traveling Salesman Problem and Its Variations, *Springer Science & Business Media* (2006)
- [5] Yannakakis, M.: Expressing Combinatorial Optimization Problems by Linear Programs, *Journal of Computer and System Sciences*, Vol. 43, No. 3, pp. 441-446 (1991)
- [6] Helsgaun, K.: General k-Opt Submoves for the LinKernighan TSP Heuristic, *Mathematical Programming Computation*, Vol. 1, No. 2-3, pp. 119-163 (2009)
- [7] Kirkpatrick, S., Gelatt Jr., D. C., Vecchi, M.: Optimization by Simulated Annealing, *Science*, Vol. 220, No. 598, pp. 671-680 (1983)
- [8] Laporte, G., Martello, S.: The Selective Traveling Salesman Problem, *Discrete Applied Mathematics*, Vol. 26, No. 2-3, pp. 193-207 (1990)
- [9] 柴田祐樹, 高間康史: 辺ベクトルを用いた観光経路推薦問題の定式化と焼きなまし法による解法の提案, 知能と情報, Vol. 31, No. 1 (2019)
- [10] Browne, C., Powley, E., Whitehouse, D., Lucas, S., Cowling, I. P., Rohlfshagen, P., Tavener, S., Perez, D., Samothrakis, S., Colton, S.: A Survey of Monte Carlo Tree Search Methods, *IEEE Transactions on Computational Intelligence and AI in Games*, Vol. 4, No. 1, pp. 1-43 (2012)
- [11] Vose, D. M.: Modeling Simple Genetic Algorithms, *Journal of Evolutionary Computation*, Vol. 3, No. 4, pp. 453-472 (1955)
- [12] Metropolis, N., Rosenbluth, A., Rosenbluth, M., Teller, A.: Equation of State Calculations by Fast Computing Machines, *The Journal of Chemical Physics*, Vol. 21, No. 6, pp. 1087-1092 (1953)
- [13] Geman, S., Geman, D.: Stochastic Relaxation, Gibbs distributions, and the Bayesian Restoration of Images, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. PAMI-6, No. 6, pp. 721-741 (1984)
- [14] Shibata, H., Takama, Y.: Index-based Notation for Random Variable and Probability Space, *Journal of Advanced Computational Intelligence and Intelligent Informatics*, Vol. 23, No. 4, 4 pages (2019)
- [15] Chan, M. T.: More Algorithms for All-Pairs Shortest Paths in Weighted Graphs, *Proceedings of the 39th Annual ACM Symposium on Theory of Computing*, pp. 590-598 (2007)
- [16] C. M. Bishop: Pattern Recognition and Machine Learning, Chapter 11, *Springer*, 8th printing (2006)
- [17] Matsumoto, M., Nishimura, T.: Mersenne Twister: A 623-Dimensionally Equidistributed Uniform Pseudorandom Number Generator, *ACM Transactions on Modeling and Computer Simulation*, Vol. 8, No. 1, pp. 3-31 (1998)