

部分的完全調査モンテカルロ法の提案と 不確実性を含んだプランニングへの適用

小野寺将輝[†] 川村 秀憲[†] 大内 東[†]

[†] 北海道大学大学院情報科学研究科 〒060-0814 北海道札幌市北区北14条西9丁目

E-mail: †{onodera,kawamura,ohuchi}@complex.eng.hokudai.ac.jp

あらまし 期待値の推定精度を向上させる部分的完全調査モンテカルロ法を提案し、実験によってその有効性を示した。また、複数の異なる結果が生起する可能性があり、どの結果が生起するかを事前に一意に決定できないという不確実性を含むプランニングの一例である Tour Planning Problem に対して、結果を確率的に捉え、提案手法を用いて得られる効用の期待値を推定し、プランの評価値として使用するという方法を適用した。実験結果から、期待値の推定精度が向上することで、より安定して高い評価値を持つ解を探索することが可能となった。

キーワード 部分的完全調査モンテカルロ法, Tour Planning Problem, 不確実性, プランニング

Proposal of partially exhaustive evaluation Monte Carlo Method and application to the planning containing the uncertainty

Masaki ONODERA[†], Hidenori KAWAMURA[†], and Azuma OHUCHI[†]

[†] Graduate School of Information Science and Technology, Hokkaido University Kita 14 Nishi 9, Kita-ku, Sapporo, 060-0814 Japan

E-mail: †{onodera,kawamura,ohuchi}@complex.eng.hokudai.ac.jp

Abstract In this paper, we propose the partially exhaustive evaluation Monte Carlo Method, which improves the accuracy of estimation of expected value, and evaluate the effectiveness of the proposed method. Moreover, we apply the proposed method to the Tour Planning Problem, which includes the uncertainty that a result to a single solution cannot be determined uniquely. From experimental results, it has been confirmed that the accuracy of estimation is improved by the proposed method, and as a result, the effectiveness of searching is improved.

Key words partially exhaustive evaluation Monte Carlo Method, Tour Planning Problem, uncertainty, planning

1. はじめに

近年、電子商取引や企業における設備保守計画の立案、あるいは観光産業への IT システムの応用など様々な分野において、ソフトウェアによる自動的なプランニングに関する研究が行われている [1] [2] [3]。これらは、ある場面において選択可能なプランの候補が多数存在し、それぞれのプランに対して複数の異なる結果が生起する可能性があるため、どのプランに対してどの結果が生起するかを事前に一意に決定することができないという不確実性を含む。このとき、結果への不確実性を考慮してプランを評価する方法の一つに、結果を確率的に捉え、モンテカルロ法を用いて得られる効用の期待値を推定するという方法がある [4]。この方法は、対象とする問題に特別な仮定を必要としないという利点を持つが、推定精度の向上には多くのサンプルが必要となる。しかし、実際には計算時間に対する制約が存

在するため、あまり多くのサンプルを使用できない場合が多く、少ないサンプルでできるだけ正確に推定する方法が望まれる。一方で、複数の独立な確率事象の組み合わせとして結果を定義できる場合には、それぞれのプランに対する生起確率の高い結果を列挙することが比較的容易に実現できる可能性がある。

そこで本研究では、この特徴を利用することで、期待値に大きく寄与すると考えられる結果を効率よく抽出し、ある固定された計算コストのもとでの期待値の推定精度を向上する部分的完全調査モンテカルロ法を提案する。また、不確実性を含んだプランニングの一例である Tour Planning Problem に提案手法を適用し、その有効性に関する評価を行う。ここで期待値の推定に要する実際の計算時間は、対象とする問題の性質や計算機環境などによって大きく変化すると考えられる。そこで本稿では実際の計算時間ではなく、期待値の推定に使用するサンプル数を推定に要する計算コストの基準として用いることとする。

2. 部分的完全調査モンテカルロ法

2.1 本研究が対象とする問題の定式化

選択可能なプランの候補が複数存在し、選択された一つのプランに対して、複数の結果の候補の中から一つが確率的に生起する場合を考える。各結果の生起確率は既知であり、結果ごとに効用が計算される。あるプランを選択した場合に得られる効用の期待値をそのプランの評価値として用いる場合、得られる効用の期待値を最大化する問題として定式化できる。まず、選択可能なプラン s_i の集合を S とする。また、あるプラン s_i に対して生起する可能性のある結果 x_{ij} の集合を X_i とする。

$$S = \{s_i | i = 1, 2, \dots, W\}. \quad (1)$$

$$X_i = \{x_{ij} | j = 1, 2, \dots, N_i\}. \quad (2)$$

x_{ij} の生起確率と得られる効用をそれぞれ $p(x_{ij})$, $e(x_{ij})$ とし、 s_i の評価値を $E(s_i)$ とすると、以下のように定式化できる。

$$\text{目的関数: } \max_{s_i} E(s_i) \left(= \max_{s_i} \sum_{j=1}^{N_i} e(x_{ij}) \cdot p(x_{ij}) \right) \quad (3)$$

このとき、 X_i が K_i 個の独立な集合 Y_{ik} の直積集合として定義できるものとする。

$$X_i = Y_{i1} \times Y_{i2} \times \dots \times Y_{iK_i} \quad (4)$$

$$Y_{ik} = \{y_{ikl} | l = 1, 2, \dots, L_k\} \quad (k = 1, 2, \dots, K_i) \quad (5)$$

ここで、 Y_{ik} は結果を構成する各要素の集合を表す。 y_{ikl} の生起確率 $p(y_{ikl})$ は既知とする。つまり x_{ij} は、 y_{ikl} のある一つの組合せを表し、 $p(x_{ij})$ は対応する各 $p(y_{ikl})$ の積として計算される。 X_i と Y_{ik} の関係を図1に示す。このように定式化される問題において W や N_i が大きくなると、計算時間に対する制約から、全ての s_i に関して実際に $E(s_i)$ を計算することは困難となる。本稿ではモンテカルロ法を用いて $E(s_i)$ を推定する。

2.2 生起確率が高い結果の列挙の方法

前述のように、 Y_{ik} の直積集合として X_i が定義され、 $p(x_{ij})$ を対応する各 $p(y_{ikl})$ の積として計算可能な場合、 X_i の全要素を調べなくとも、 $p(x_{ij})$ に対して閾値を設定し、その閾値よりも大きな $p(x_{ij})$ を持つ x_{ij} だけを列挙することが可能である。列挙のアルゴリズムを図2に示す。計算は $target = 1.0$, $candidate = 1$ を初期値として実行する。各 $p(y_{ikl})$ の積として $p(x_{ij})$ を計算する過程において、閾値を下回った時点でその先の計算を省略するという枝刈りを行い、 $p(x_{ij})$ が閾値以上である x_{ij} のみを保存する。閾値を適切に設定することで、省略可能な計算が増加し、列挙に要するコストを軽減できる。

2.3 部分的完全調査モンテカルロ法の提案

生起確率の高い結果を列挙することが比較的容易であるという特徴を利用し、それら列挙された結果に関して完全調査を行うことで期待値の推定精度を向上する部分的完全調査モンテカルロ法を提案する。以下で、提案手法による $E(s_i)$ の推定手順を説明する。このとき、推定に使用するサンプル数は M とする。まず手順1として、結果の集合 X_i を生起確率が閾値以上である結果の集合 $X_i^{(1)}$ とそれ以外の結果の集合 $X_i^{(2)}$ に分割す




図1 X_i と Y_{ik} の関係




図2 列挙のアルゴリズム

る。 $X_i^{(1)}$ の要素数を $|X_i^{(1)}|$ と表す。 $X_i^{(1)}$, $X_i^{(2)}$ の推定に使用するサンプル数をそれぞれ M_1 , M_2 とすると $M_1 + M_2 = M$ である。手順2として、 $X_i^{(1)}$ に含まれる全要素に関して完全調査を行う。完全調査の結果 E_1' は以下のように計算される。

$$E_1' = \sum_{x_{ij} \in X_i^{(1)}} e(x_{ij}) \cdot p(x_{ij}). \quad (6)$$

このとき、 $M_1 = |X_i^{(1)}|$ である。手順3として、 $X_i^{(2)}$ に関して加重サンプリングモンテカルロ法で推定を行う。しかしここで、 $X_i^{(2)}$ に含まれる要素だけを効率良くサンプリングすることが困難であるという問題が生じる。そこで本稿では、 X_i から $p(x_{ij})$ にしたがって加重サンプリングを行い、その中から $X_i^{(2)}$ に含まれるサンプルのみを使用することとする。このとき、サンプリング回数を M_2 に固定する方法と使用できるサンプルが M_2 個揃うまでサンプリングを続ける方法という二種類が考えられるが、計算時間の制約から後者はあまり現実的な方法とは言えないため、本稿では前者を採用する。この場合、実際に推定に使用できるサンプル数を M_2' とすると、 M_2' は M_2 よりも少なくなる可能性がある。理論上は、 $M_2' = M_2 \cdot (\sum_{x_{ij} \in X_i^{(2)}} p(x_{ij}))$ となる。これら M_2' 個のサンプルを $\xi_{i1}^{(2)}, \xi_{i2}^{(2)}, \dots, \xi_{iM_2'}^{(2)}$ とすると、 $X_i^{(2)}$ に関する推定結果 E_1'' は以下のように計算される。

$$E_1'' = \frac{1}{M_2'} \sum_{u=1}^{M_2'} e(\xi_{iu}^{(2)}). \quad (7)$$

最後に手順4として、期待値の推定値 E_1 を計算する。また、その分散を $var E_1$ とすると、それぞれ以下のように計算される。

$$E_1 = E_1' + \sum_{x_{ij} \in X_i^{(2)}} p(x_{ij}) \cdot E_1''. \quad (8)$$

$$var E_1 = \frac{\sum_{x_{ij} \in X_i^{(2)}} p(x_{ij})}{M - |X_i^{(1)}|} var (e(\xi_i^{(2)})). \quad (9)$$

次に比較の対象として、従来の加重サンプリングモンテカルロ法による期待値の推定値 E_2 とその分散 $var E_2$ を示す[5]。 $\xi_{i1}, \xi_{i2}, \dots, \xi_{iM}$ を $p(x_{ij})$ にしたがって X_i からサンプリングした M 個のサンプルとすると、以下のように計算される。

$$E_2 = \frac{1}{M} \sum_{u=1}^M e(\xi_{iu}). \quad (10)$$

$$var E_2 = \frac{1}{M} var (e(\xi_i)). \quad (11)$$

推定に要する計算コストを固定する場合、推定値の分散を比較することで推定精度を比較できる。(9)式と(11)式の比較が

ら、提案手法により精度を向上するための条件式が得られる。

$$\frac{M_2}{M} \cdot \text{var}(e(\xi_i)) \geq \sum_{x_{ij} \in X_i^{(2)}} p(x_{ij}) \cdot \text{var}(e(\xi_i^{(2)})). \quad (12)$$

つまり、 X_i の要素に関する効用の分散 $\text{var}(e(\xi_i))$ に対して $X_i^{(2)}$ の要素に関する効用の分散 $\text{var}(e(\xi_i^{(2)}))$ があまり変化せず、かつ M に対する M_2 の割合よりも $X_i^{(2)}$ の要素が占める生起確率の和が小さくなるように X_i を分割できる場合には、提案手法により推定精度を向上できると考えられる。

3. 提案手法の有効性を評価する実験

3.1 設定

実験により手法ごとの推定精度を比較する。各目の生起確率が異なるさいころを複数同時に振り、出た目の組合せによってスコアが決まる状況を仮定し、得られるスコアの期待値を推定する。2.1節の定式化と対応させると、与えられたある複数のさいころの組がある s_i 、各さいころの出目が y_{ikl} 、その生起確率が $p(y_{ikl})$ 、目の組合せが x_{ij} 、その組合せの生起確率が $p(x_{ij})$ 、 x_{ij} に対して割り当てられたスコアが $e(x_{ij})$ である。ここでは、10種類の目を持つさいころを6個同時に振ることとする。したがって、目の組合せ総数は1,000,000通りとなる。ただし、同時に振る6個のさいころは同じ生起確率の分布を持つものとし、異なるさいころを混ぜて使用することは行わない。全ての目の組合せに対して $N(100.0, 1.0)$ にしたがってランダムにスコアを割り当てる。また、 $M = 1000$ と固定して実験を行う。

3.2 実験 1

a) 実験 1-1 設定

まず、図3に示すような、6個同時に振った場合の1,000,000通りの組合せに関する生起確率の分散が異なる3種類のさいころの設定を用意する。提案手法と加重サンプリングモンテカルロ法を用いて設定ごとに1000試行の推定を行い、事前に計算した真値との平均誤差率を計算する。このとき、完全調査個数 $|X_i^{(1)}|$ を0から900まで100刻みで変化させて精度を考察する。実際に提案手法を使用する際には、 $|X_i^{(1)}|$ を直接指定することは困難であるが、ここでは手法の基本的な性質を調べるため、生起確率の大きい順に目の組合せを並べたデータベースを事前に用意し、これを参照することで $|X_i^{(1)}|$ を直接指定する。

b) 実験 1-1 結果

図4は、各さいころの設定に関する1000試行の推定の平均誤差率の変化である。 $|X_i^{(1)}| = 0$ は加重サンプリングモンテカルロ法に相当する。生起確率の偏りが小さい場合には、完全調査を加えることで精度が低下している。しかし、確率の偏りが大きい場合には、完全調査を行う個数によっては、提案手法の使用により加重サンプリングモンテカルロ法よりも高い推定精度が実現されている。したがって、確率の偏りが大きい場合ほど提案手法は有効であり、提案手法の使用にあたっては、完全調査を行う個数を適切に設定することが重要であると言える。

c) 実験 1-2 設定

次に、生起確率の分散が異なるさいころの設定を100種類用意し、各さいころに対して、 $|X_i^{(1)}| = 100$ と設定した提案手法と加重サンプリングモンテカルロ法を用いて同様の実験を行う。






図3 3種類のさいころ

図4 平均誤差率の変化



(a) 1000 試行の平均誤差率

(b) 1000 試行での推定値の分散



(c) $\text{var}(e(\xi_i))$ と $\text{var}(e(\xi_i^{(2)}))$ の比較

(d) $\sum_{x_{ij} \in X_i^{(2)}} p(x_{ij})$ と $\frac{M_2}{M}$ の変化

図5 $|X_i^{(1)}| (= M_1)$ を100に固定した場合

d) 実験 1-2 結果

図5(a), 5(b)は、各さいころの目の組合せの生起確率の分散を横軸にとり、それぞれに対する各手法の平均誤差率および推定値の分散をプロットしたグラフである。また図中の線は、2次の線形近似曲線を示している。生起確率の分散が大きい場合、すなわち生起確率の偏りが大きい場合に、提案手法によって推定精度を向上できることがわかる。図5(c), 5(d)は、(12)式に含まれる各値の変化である。効用の分散に関しては、ほとんど違いは見られない。それに対して $\sum_{x_{ij} \in X_i^{(2)}} p(x_{ij})$ は、生起確率の分散が大きいほど小さな値を示している。この値が $\frac{M_2}{M}$ よりも小さくなる点と、提案手法の推定精度が加重サンプリングモンテカルロ法を超える点はほぼ一致している。したがって、(12)式が示す条件を満たす場合には、提案手法による精度の向上が可能であり、そのような状況が実際に存在することも確認された。

3.3 実験 2

e) 実験 設定

実際には、 $|X_i^{(1)}|$ を直接指定することは困難である。そこで、生起確率に対して閾値を設定し、それよりも生起確率の大きい結果だけを列挙して完全調査を行う。ここでは、実験 1-1 で用いた3種類のさいころに関して、11種類の異なる閾値を用いて10000試行の推定を行い、平均誤差率を比較する。これらの閾値は、予備実験の結果から経験的に設定した。

f) 実験 結果

図6(a), 6(b), 6(c)は、各設定において各閾値を用いた場合の平均誤差率と完全調査個数である。閾値が1.0の場合は加重

サンプリングモンテカルロ法に相当する。設定1では確率の偏りが小さく、ほとんどの閾値に関して、それより大きい生起確率を持つ結果が存在しないために完全調査が行われず、精度の変化が見られない。0.0002の場合にのみ完全調査が行われているが、逆に精度は低下している。これは、設定1においては、0.0002という閾値の設定が適切ではなかったためと考えられる。一方、設定2および設定3では、閾値を適切に設定することで、ある程度数の結果に関して完全調査が行われ、推定精度が向上されている。したがって、閾値を適切に設定することで精度を向上できる場合があり、最悪でも加重サンプリングモンテカルロ法と同等の精度は得られると考えられる。図6(d)は、10000試行の所要時間である。設定1において完全調査個数が0である間は少しずつ所要時間が増加しているが、それ以外では完全調査の個数が増えるにつれて所要時間は減少している。これは、列挙に要する時間は増加するが、完全調査された数だけランダムなサンプリング回数が減少し、使用する乱数の数が減少するため、全体として計算時間が短縮されたためである。つまり、実際の計算時間の面でも提案手法が有効な場合があると言える。これらの結果から、閾値を適切に設定することで、提案手法により精度を向上できる場合があると確認された。

3.4 実験 3

g) 実験設定

提案手法を用いるにあたり、事前に予備実験を繰り返して適切な閾値を設定することは負担となる。そこで、実際の期待値の推定と平行して、事前に用意した複数の候補から適切な閾値を学習することを試みる[6]。これは、一度きりの推定を行う場合には実行が困難であり、同じような推定を複数回繰り返して行う場合を想定している。例えば、SAの探索と平行して閾値を学習し、最終的には適切な閾値のみを使用して高い推定精度で解評価を行うことなどが考えられる。設定としては、生起確率の偏りが異なるさいころを10000種類用意し、それぞれを6個同時に振った場合のスコアの期待値を一度だけ推定することを繰り返しながら、閾値を学習する。推定のたびに、ボルツマン分布に基づき、その時点での各閾値の推定値から選択確率を計算し、閾値を一つ選択する。その閾値を用いて期待値の推定を行うと同時に、その閾値に対する報酬 r を計算して推定値を更新する。推定値は、それまでに得た報酬の標本平均とする。報酬 r は、(9)式と(11)式において $\text{var}(e(\xi_i))$ に対して $X_i^{(2)}$ が変化しないという前提のもと、以下のように定義する。

$$r = \frac{1}{M} - \frac{\sum_{x_{ij} \in X_i^{(2)}} p(x_{ij})}{M - |X_i^{(1)}|}. \quad (13)$$

候補は、前節の11種類から0.0004~0.0002を除いた8種類とする。これらは本節の実験設定で使用した際に $|X_i^{(1)}|$ が M を超える場合が確認されたため除外した。これらも候補として保持しておき、 $|X_i^{(1)}|$ が M を超えた時点で候補から外すという方法も考えられるが、ここでは扱わない。ボルツマン分布における温度パラメータはの初期値は0.01と設定し、 $T > 0.000001$ を満たす間は10回推定を行うたびに0.99倍ずつ温度を下げることにする。このように、閾値の選択、期待値の推定、閾値の

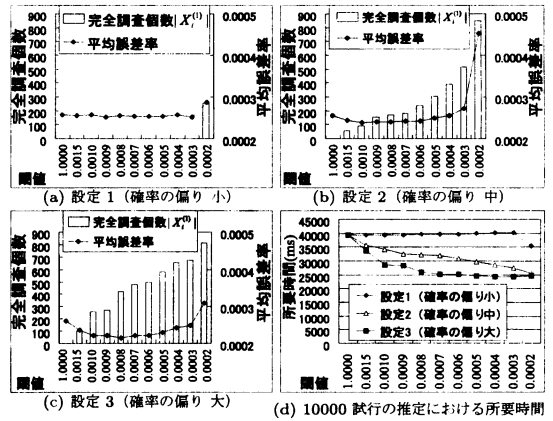


図6 閾値を用いた場合の平均誤差率、完全調査個数および計算時間

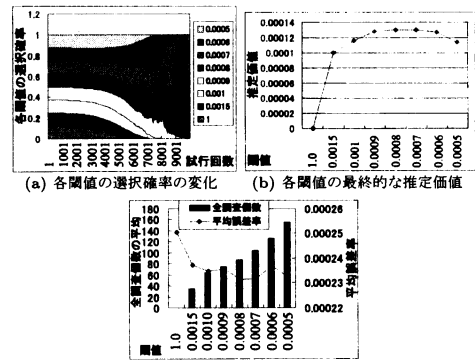


図7 閾値の学習に関する実験結果

推定値の更新を繰り返しながら、適切な閾値を学習する。

h) 実験結果

図7(a), 7(b)は、各閾値の選択確率の変化および最終的な推定値である。温度が低い初期段階では全ての閾値がほぼ等確率で選択されているが、最終的には0.0007と0.0008の選択確率が高い状態へ収束している。これら2つの閾値の最終的な推定値はほぼ等しい値を示している。また、図7(c)は、学習と平行して、それとは独立に各閾値に固定し、10000種類に関して一回ずつ推定を行った場合の平均二乗誤差である。この平均値は、その一回の推定が正確だったかどうかに影響されて、多少のばらつきを含むと考えられるが、0.0007と0.0008に固定した場合には明らかに高い精度が実現されていることがわかる。これらの結果から、期待値の推定と平行して閾値を学習することで、適切な閾値を設定できる場合があることが確認された。

4. Tour Planning Problem への適用

4.1 概要

複数の観光施設の中から、スコアを最大化するようなTour、すなわち訪れる施設とその順序を決定する。施設間の移動時間や各施設での滞在時間が確率的に与えられる場合には、全体の

所要時間が定まらず、その Tour から得られるスコアを一意に決定できないという不確実性を含む。そこで、提案手法を用いて得られるスコアの期待値を推定し、評価値として使用することで、安定して高いスコアを得られる Tour の探索を試みる。

4.2 定式化

観光施設を表すノードの集合を V 、時刻集合を T とする。

$$V = \{v_1, \dots, v_n\}. \quad (14)$$

$$T = \{t_r | t_r = t_1 + (r-1) \cdot \delta t, r = 1, 2, \dots\}. \quad (15)$$

δt は単位時間を表す。 v_i は営業開始時刻 o_i 、営業終了時刻 e_i を持つ ($o_i, e_i \in T$)。 v_i から v_j への移動および v_i での滞在に要する時間コストの集合をそれぞれ W_{ij} 、 W_i と表す。

$$W_i = \{w_{ik} | w_{i,k+1} = w_{ik} + \delta t, k = 1, \dots, m_i\}. \quad (16)$$

$$W_{ij} = \{w_{ijk} | w_{i,j,k+1} = w_{ijk} + \delta t, k = 1, \dots, m_{ij}\}. \quad (17)$$

また、 v_i に w_{ik} の間滞在する確率 $p_i(w_{ik})$ ($\sum_k p_i(w_{ik})=1$)、 v_i から v_j への移動に w_{ijk} を要する確率 $p_{ij}(w_{ijk})$ ($\sum_k p_{ij}(w_{ijk})=1$) がそれぞれ設定される。出発地 v_s 、最終目的地 v_g 、出発時刻 D_s 、制限時刻 D_g を定義すると、以下のように定式化される。

目的関数：

$$\max \sum_{b \in B} (S(A, b) \cdot p(b)) = \max E[S(A, b)]. \quad (18)$$

$$A = (a_{ui})_{u=1, \dots, n, i=1, \dots, n} \quad (a_{ui} \in \{0, 1\}). \quad (19)$$

$$S(A, b) = \begin{cases} \sum_{u=2}^{L-1} s_{a(u)}(t_u) : t_L \leq D_g \\ -1 : t_L > D_g \end{cases}. \quad (20)$$

$$s_i(t) = \begin{cases} s_i : o_i \leq t \leq e_i \\ 0 : otherwise \end{cases}. \quad (21)$$

$$B = W_{a(1)} \times \dots \times W_{a(L)} \times W_{a(1), a(2)} \times \dots \times W_{a(L-1), a(L)}. \quad (22)$$

$$b = (c_{a(1)}, \dots, c_{a(L)}, c_{a(1), a(2)}, \dots, c_{a(L-1), a(L)}). \quad (23)$$

$$p(b) = \prod_{u=1}^L p_{a(u)}(c_{a(u)}) \times \prod_{u=1}^{L-1} p_{a(u), a(u+1)}(c_{a(u), a(u+1)}). \quad (24)$$

$$t_\xi = D_s + \sum_{u=2}^{\xi-1} c_{a(u)} + \sum_{u=1}^{\xi-1} c_{a(u), a(u+1)}. \quad (25)$$

$$L = \sum_{u=1}^n \sum_{i=1}^n a_{ui}. \quad (26)$$

$$a(u) = \sum_{i=1}^n (a_{ui} \cdot i). \quad (27)$$

制約条件：

$$a_{1,s} = a_{L,g} = 1. \quad (28)$$

$$\sum_{u=1}^n a_{ui} \leq 1. \quad (29)$$

$$\sum_{i=1}^n a_{ui} \leq 1. \quad (30)$$

$$\sum_{i=1}^n a_{u+1,i} \leq \sum_{i=1}^n a_{ui}. \quad (31)$$




図 8 $p_{ij}(w_{ijk})$ および $p_i(w_{ik})$ の設定方法の概要

表 1 3 種類の観光客の設定 (出発時刻と制限時刻)

	D_s	D_g
設定 1	14:00	23:00
設定 2	8:00	18:00
設定 3	9:00	21:00

(18) 式は目的関数であり、期待値の最大化を表す。(19) 式は Tour を表す行列で、 $a_{ui} = 1$ は u 番目に v_i を訪れることを表す。(20) 式はスコアを表す。本稿では、制限時刻として列車などの出発時刻を仮定するため、それを超過した場合のスコアを -1 と設定したが、超過が許容される場合には、ペナルティを加算する方法も考えられる。(21) 式は時刻 t における v_i の評価値を表す。(22) 式は、時間コストの組合せから構成される直積集合を表す。(23) 式が示すように、 $b \in B$ は任意のコストの組合せを表す。ここで c_i および c_{ij} は、 $p_i(w_{ik})$ および $p_{ij}(w_{ijk})$ にしたがって決定される任意のコストである。(24) 式は b の生起確率、つまり任意の c_i および c_{ij} が同時に選択される確率を表す。(25) 式は ξ 番目のノードへの到着時刻、(26) 式は訪れるノードの数、(27) 式は u 番目に訪れるノードの番号を表す。

4.3 実験設定

北海道札幌市における 14 の観光施設を参考にモデルを作成した。 $p_{ij}(w_{ijk})$ は以下のように設定する。まず、 v_i から v_j への移動に要する標準時間コスト μ_{ij} を市販の地図ソフトにより決定する。次に、 μ_{ij} を K で除算した値を σ_{ij} と設定する。ここで K は、時間コストのばらつきを設定するためのパラメータである。最後に、図 8 に示すように $N(\mu_{ij}, \sigma_{ij})$ を単位時間 δt で分割して $p_{ij}(w_{ijk})$ を設定する。 $p_i(w_{ik})$ も同様に設定する。 μ_i はガイドブックを参考に決定した。各 o_i 、 e_i は現実の値を用いる。本実験では、 $\delta t = 5$ 、 $K = 15$ と設定する。

4.4 期待値の推定精度を比較する実験

i) 実験設定

表 1 に示す 3 種類の客を設定する。各施設の評価値は客ごとにランダムに設定する。設定 1 では、時刻次第でいくつかの施設が営業を終了する場合がある。設定 2 では、いくつかの施設が営業開始前である場合があり、設定 1 よりも観光に利用できる時間が長い。設定 3 では、観光に利用できる時間が最も長い。期待値の推定精度を比較するために、設定ごとにランダムな 1000 種類の Tour を用意し、提案手法および加重サンプリングモンテカルロ法を用いて各 Tour に関して 10000 試行の推定を行い、真値との平均二乗誤差を計算する。 M は 450 と 500、閾値は 0.0075 と 0.003 の各 2 種類に設定する。

j) 実験結果

図 9 は、各手法による平均二乗誤差である。設定 1 では、閾




図 9 各手法の設定ごとの平均二乗誤差

値を適切に設定することで推定精度が最大約 4.4% 向上している。設定 2 では、精度が約 0.8% ほど向上されているが設定 1 と比較すると向上率は低い。設定 3 では、精度に変化は見られなかった。この理由として、観光に利用できる時間の差が挙げられる。時間が長いとより多くの施設を訪れるため、考える時間コストの組合せが増加し、それぞれの生起確率も相対的に小さくなる。そのため、完全調査される組合せが減少し、それらが占める生起確率も小さくなるため、提案手法の効果が減少したと考えられる。しかし、精度の低下は見られないため、 M に対して閾値を適切に設定すれば提案手法は有効であると言える。


4.5 SA を用いて探索を行う実験

k) 実験設定

推定精度の向上により、解評価の安定による探索精度の向上が期待できる。また、加重サンプリングモンテカルロ法と同等の推定精度を保つように M を減らして他の解の評価へ利用し、以前と同等の推定精度のままより多くの解を評価することで探索精度を向上できる可能性もある。そこで、精度の向上が見られた設定 1, 2 に関して SA による探索を 1000 試行を行い、最終解を比較する。SA の設定は予備実験により決定した。ここで、SA の各温度で推定に使用するサンプル総数を 150,000 個に固定する。つまり、 M の設定により各温度で評価できる解の個数が決定される。ここでは、 $M = 500$ と設定した加重サンプリングモンテカルロ法と提案手法 (各温度で 300 個の解を評価)、 $M = 500$ の加重サンプリングモンテカルロ法と同程度の精度になるように M を調整した提案手法 (設定 1 では $M = 480$ で 312 個の解を評価、設定 2 では $M = 495$ で 303 個の解を評価) の 3 種類を比較する。提案手法の閾値は 0.003 とする。

1) 実験結果

図 10 は、1000 試行の SA で決定された 1000 個の最終解に関して、スコアの期待値の平均を計算した結果および探索一回あたりの計算時間である。設定 1 においては、提案手法を用いることで平均値が増加し標準偏差が抑制されている。また、 $M = 480$ と設定した場合の方が標準偏差が多少小さくなっている。どちらの場合においても提案手法を用いることで、高い評価値を持つ解を安定して探索できるようになったと言える。一方、設定 2 においては、手法ごとの結果の違いは見られない。これは、標準偏差が小さいことから、設定 2 では低い評価値を持つ局所解に陥ってしまう可能性が元々低く、常に高い評価値を持つ解を発見できているためと考えられる。つまり、設定 1 のような局所解に陥る可能性が高い場合には、提案手法が有効であると言える。実際の計算時間も提案手法によって短縮され



(c) SA 一回当たりの計算時間 (設定 1) (d) SA 一回当たりの計算時間 (設定 2)

図 10 1000 試行の SA における最終解の期待スコアと計算時間

ており、この結果からも提案手法の有効性が確認できる。また、これらの最終解に関して、制限時刻を超えてしまう確率は大きい場合でも約 0.1% 程度であった。したがって、期待値を用いて解の評価を行うことで妥当な解を探索できたとと言える。

5. 結 論

生起確率の高い結果の列挙を容易に実現できるという特徴を利用し、期待値の推定精度を向上する部分的完全調査モンテカルロ法を提案した。また、不確実性を含んだプランニングにおいて、得られる効用の期待値を推定し、評価値として使用する方法へ提案手法を適用した。まず、提案手法の有効性を式の展開と実験によって確認した。実験結果から、結果の生起確率の偏りが大きいほど提案手法が有効であることがわかった。また、提案手法の有効性に影響する閾値の設定を学習により調整する方法を提案した。次に、不確実性を含んだプランニングの一例である Tour Planning Problem へ提案手法を適用した。実験結果から、提案手法によって期待値の推定精度が向上され、より安定して高い評価値を持つ解を探索することが可能となった。今後の課題としては、分散の推定が挙げられる。それにより、期待値と分散に基づいた解の評価が可能となると考えられる。

謝辞 本研究を進めるにあたり多大なご協力、ご助言を下さった、産業技術総合研究所 情報技術研究部門の車谷浩一氏に深く感謝いたします。

文 献

- [1] Michael P. Wellman, Peter R. Wurman, "A Trading Agent Competition for the Research Community", IJCAI-99 Workshop on Agent-Mediated Electronic commerce, Stockholm, 1999.
- [2] 松田 善臣, 名嘉村 盛和, 姜 東植, 宮城 隼夫, "最遠観光経路問題とその解法", 電気学会論文誌 C, 124 巻 7 号, p.1507-1514, 2004.
- [3] 山崎 伸見, 手塚 大, 樋地 正浩, "モンテカルロシミュレーションと遺伝的アルゴリズムによる設備保守計画の最適化", Forum on Information Technology (FIT2003), CD-ROM.
- [4] J. MICHAEL FITZPATRICK, JOHN J. GREFFENSTETTE, "Genetic Algorithm in Noisy Environments", Machine Learning, Vol.3, pp.101-120, 1988.
- [5] 津田孝夫, "モンテカルロ法とシミュレーション", 培風館, 1977.
- [6] 三上 貞芳, 皆川 雅章 共訳, "強化学習", 森北出版, 2000.