

ヒューリスティック知識の利用に学習を導入した グラフ探索の効率化

1P-1

笹尾茂樹^{*1} 吉田耕司^{*2} 菅田一博^{*1} 井須尚紀^{*1} 清水忠昭^{*1}^{*1}鳥取大学^{*2}日本アイ・ビー・エム株式会社

1. はじめに

一見複雑そうに見える問題でも、グラフで表現すれば整理され、考えやすくなる。このため、人工知能の研究では、問題をグラフで表現し、グラフ探索で問題を解くことがよく行われる。

現実には、与えられた問題に対して、異なった様々な制約条件下で解を求める場面に遭遇することが多い。このような場合、ある制約条件下で求めた最適解を別の制約条件下で解を求めるときに利用できれば、以後のグラフ探索で解を求めるまでに費やされる時間は少なくてすむと考えられる。

本研究の目的は、ヒューリスティック探索によって求めた解を、ヒューリスティックな知識に反映させることにより、それ以後の様々な制約条件下でのグラフ探索の効率化をもたらす新しい方法を提案することにある。

2. ヒューリスティック探索

本研究では、ヒューリスティック探索に属するA*アルゴリズムをグラフ探索法として用いる。任意の節点をnとしたとき、A*アルゴリズムは、節点nから目標節点までのコストの推定値 $\hat{h}(n)$ を用いたグラフ探索法である。真値 $h(n)$ と推定値 $\hat{h}(n)$ との間に次式の関係が成立すれば、A*アルゴリズムは、最適解を見つける。

$$\hat{h}(n) \leq h(n)$$

3. 学習による推定値の修正方法

本研究で提案した学習方法は、任意の節点nから目標節点までのコストの推定値 $\hat{h}(n)$ を真値 $h(n)$ へと近づけるための、推定値 $\hat{h}(n)$ の修正方法が基本となっている。

推定値 $\hat{h}(n)$ は真値 $h(n)$ に近い値であるほど解を求めるまでに展開される節点数は少なくなり、グラフ探索に費やされる時間も少なくなる。1回目のグラフ探索によって求めた最適解上の道の節点から出発節点と目標節点を除いたものを $k_1, \dots, k_i, \dots, k_p$ として、次のことを考える。1回目のグラフ探索で用いた推定値 $\hat{h}(k_i)$ よりも真値に近づいた推定値 $\hat{h}_A(k_i)$ が $\hat{h}(k_i)$ の一次関数で表されると仮定し $\hat{h}_A(k_i)$ を次式で表す。

$$\hat{h}_A(k_i) = \alpha\hat{h}(k_i) + \beta$$

このとき、 $h(k_i) - \hat{h}_A(k_i)$ の自乗誤差の平均を最小とする α, β を求める。自乗誤差の平均Aは、

$$\begin{aligned} A &= E\{h(k_i) - \hat{h}_A(k_i)\}^2 \\ &= E\{h(k_i) - (\alpha\hat{h}(k_i) + \beta)\}^2 \end{aligned}$$

となる。このAを最小にする α, β を計算する。

$$\frac{\partial A}{\partial \alpha} = 0, \quad \frac{\partial A}{\partial \beta} = 0$$

より、 α, β は次のようになる。

$$\begin{aligned} \alpha &= \frac{\overline{h(k_i)} \overline{\hat{h}(k_i)} - \overline{h(k_i)} \overline{\hat{h}(k_i)}}{\overline{\hat{h}(k_i)}^2 - \overline{\hat{h}(k_i)}^2} \\ \beta &= \overline{h(k_i)} - \alpha \overline{\hat{h}(k_i)} \end{aligned}$$

ここに、例えば、 $\overline{h(k_i)}$ は $\sum_{i=1}^p h(k_i)/p$ である。

求めた α, β を用いて、任意の節点nの推定値 $\hat{h}(n)$ を、

$$\hat{h}_A(n) = \alpha\hat{h}(n) + \beta$$

によって学習的に改善できると仮定し、 $\hat{h}_A(n)$ を二回目以後のグラフ探索に使用する。

学習の効果を見るために、以上的方法を巡回セールスマン問題に適用した。

4. 巡回セールスマン問題への適用

巡回セールスマン問題において、A*アルゴリズムで使うコストの推定値の計算方法を以下に2つ示す。

(a) 推定値の計算方法1

N 個の都市のある都市から出発し、全ての都市を1回だけ訪れ出発都市に帰ってきたときの道の長さは都市

Acquisition method of heuristic knowledge for graph search
Shigeki Sasao¹, Kouji Yoshida², Kazuhiro Sugata¹,
Naoki Isu¹, Tadaaki Shimizu¹
1. Tottori Univ. 2. IBM Japan, Ltd.

の数 N と等しい。ゆえに、現在訪れている都市が何番目に訪れた都市であるかわかれれば、現在の都市から出発都市に帰るまでに必要となる道の長さと同じ個数だけ、コストの小さい順に枝を取り出し、それらの枝のコストの総和を \hat{h}_1 とする。

(b) 推定値の計算方法 2

方法 1 に次の条件を知識として取り入れる。セールスマンは出発都市を除けば、一度訪れた都市は 2 度とは訪れない。したがって、一度訪れた都市に接続する全ての枝は、以後、使われることはない。ゆえに、使う可能性のなくなった枝を全て取り除いた枝の集合から、必要となる道の長さと同じ個数だけ、コストの小さい順に枝を取り出し、それらの枝のコストの総和を \hat{h}_2 とする。

$\hat{h}_1(n), \hat{h}_2(n)$ そして、 $h(n)$ の間には次式の関係が成立する。

$$\hat{h}_1(n) \leq \hat{h}_2(n) \leq h(n)$$

方法 2 は方法 1 より知識が多いことができ、解を求めるまでに必要となる節点の展開数も方法 2 のほうが少なくなる。方法 1,2 にそれぞれ学習を施し、学習付きの探索と学習なしの探索とで解を求めるまでに生成される節点数の比較を行なう。

5. 本研究の学習方法の実験による評価と考察

(1) 実験方法

以下に示す制約条件下で、学習付きの探索と学習なしの探索とで、生成される節点数を比較する。

(制約条件)

ある都市を訪れた後は、必ず、どこの都市を訪れなければならないという制約条件があることが、現実にはしばしばある。このような条件をいくつか考え、条件 1、条件 2、…とする。

(2) 本学習方法の結果の評価

学習付きの探索と学習なしの探索とで、上に示した制約条件を満たす解を求めるまでに生成される節点数を比較した。学習によって解を求めるまでに生成された節点数は学習していないものと比べて、方法 1,2 では平均してそれぞれ約 62% と約 55% 減少した。表 1 に 1 例を示す。本学習法による探索では、必ずしも最適解を求めるとは限らない。しかし、実験の結果では、方法 1,2 では

平均してそれぞれ約 77% と約 65% は最適解を求めることができた。本学習法を用いて求めた解と最適解の差は、方法 1,2 でそれぞれ約 1.3% と約 1.1% であった。65 種の巡回セールスマン問題について、本方法で求めた解と最適解との差を、0%, 0% より大きく 5% 以下、5% より大きく 10% 以下、…、で集計した結果を図 1 に示す。

(3) 考察

本学習法は、推定値が真値より離れているものほど効果があることがわかる。また、すでに推定値が真値に近いものは学習する必要はないことを考慮すれば、本方法は非常に有効であることがわかる。

本学習方法により求めた解と最適解との差について、最近傍法で求めた解と比較する。最近傍法は求めた解と最適解との差は経験的に 20% 程度といわれている。本研究で提案した推定値の修正方法で求めた解の方が、最近傍法より非常に優れていると言える。

6. あとがき

提案した学習法の有効性を検証するために、巡回セールスマン問題を題材として取り上げた。巡回セールスマン問題に限らず、枝または節点にコストがついているグラフで、ヒューリスティックな知識を用いることができる問題であれば、本研究で提案した方法を適応できる。本論文では、推定値 \hat{h} を一次関数で修正したが、与えられた問題の推定値 \hat{h} と真値 h との関係を解析できれば、問題ごとに推定値の修正方法を変化させることにより、より効果の高い学習が期待できる。

表 1: 生成される節点数の比較

条件	1	2	3	4	5	6
学習無し	210	281	136	111	348	165
学習有り	37	67	61	24	65	24




図 1 本学習方法を用いて求めた解と最適解との差