マルチエージェント実時間探索における組織化手法

An Organizational Approach to Multiagent Real-time Search

北村 泰彦* 寺西 憲一† 辰巳 昭治‡ 奥本 隆昭§

Summary. Conventional off-line search schemes, for example A*, find a complete optimal solution path before starting to move, and the amount of computation grows exponentially as the size of problem (the number of nodes) grows. Real-time A* (RTA*), which interleaves lookahead search and move, can reduce the amount of computation at the cost of no guarantee of solution optimality. A way to improve the solution quality of RTA* is to increase the depth of lookahead horizon, but the amount of computation grows exponentially as the depth increases. An alternative way is to increase the number of agents which involve in the search. In the multiagent RTA*, each agent autonomously executes RTA* and makes a random move when multiple paths to go look equally good. The solution quality is improved as the number of agents is increased because the agents can find more undiscovered paths, and the amount of computation grows only linearly as the the number of agents increases. In this paper, we propose an organizational approach to coordinate agents in the multiagent RTA*. Our approach tries to make agents scatter by making them repelling each other. Its performance is evaluated by using maze and 15-puzzle problems. It is shown that effect of repelling among agents depends on the depth and the distribution of heuristic depressions in the state space graph.

1 はじめに

AI が対象とする試行錯誤を伴うような非決定的問題解決のための基本的な解決手法として，これまでに様々な探索手法が研究されてきた [6]．力ずくの探索手法は計算量の組合せ的爆発を招き，それに対処するために A*等のヒューリスティック探索手法が提案されるようになったが，それでも一般的には，その計算量は問題のサイズ（ノード数）に対して指数的に増加する [7]．A*はあらかじめ最適解を求めてからその移動（実行）を開始するオフライン探索と見なすことができるが，これに対して Korf は先読み探索と移動を交互に行うオンライン探索手法として実時間 A*(RTA*) [5] を提案した．RTA*では最適解を保証することはできないが，先読み探索範囲は

*Yasuhiko Kitamura, 大阪市立大学 工学部
†Ken-ich Teranishi, 大阪市立大学 工学部 （現在，日本 IBM）
‡Shoji Tatsumi, 大阪市立大学 工学部
§Takaaki Okumoto, 大阪市立大学 工学部

有限であることから計算量は改善され，解の長さに対して線形となる．ただし解の質を改善するためには先読みの範囲を広げねばならず，その計算量は先読みの深さに対して指数的である．

さて，RTA*は単一エージェント探索と見なすことができるが，Knight [3] は先読み範囲を広げるのではなくエージェントの数を増加させることによって解の質を向上させるマルチエージェント探索手法を提案した．その計算量はエージェント数に対して線形であり，Knight は先読み範囲を広げる手法と実験的に比較することにより，マルチエージェント実時間探索の有効性を示した．さらにマルチエージェント探索は並列システムに実装することが容易であり，並列探索の視点からもその有効性はさらに大きいといえる．

Knight の提案したマルチエージェント探索ではエージェントはそれぞれ自律的にRTA*を実行する．エージェントが探索過程で分岐に遭遇し，そのそれぞれの経路が同等に望ましいときには，エージェントはランダムに経路を選択する．したがってエージェント数を増加させれば，確率的により良い解経路が得られることになる．しかしながら Knight の手法では経路選択に関してエージェント間での調整が行われることはなかった．そこで本研究ではエージェントが経路選択に対して明示的な調整を行う組織化手法を提案する．すなわちエージェントは互いに他のエージェントとの位置関係を把握し，エージェントが同等に望ましい経路に遭遇した場合には他のエージェントと異なる経路を選択するように調整する．このような組織的探索を評価するために迷路探索問題 [1] と 15 パズル問題 [4] を用い，その有効性について議論している．

2 マルチエージェント実時間探索

2.1 問題の定義

マルチエージェント探索における問題は，状態の集合，オペレータの集合，初期状態，目標状態からなる状態空間グラフで表される．エージェントは，ある状態に適用可能なオペレータを適用して別の状態へ移動する．また，ある状態 x から隣接状態 yまでの移動のコストを $c(x,y)(>0)$ と表すことにする．問題の解決は，エージェントが初期状態から移動を開始し，目標状態へ到達することによりなされる．なおエージェントは，状態空間の各状態 x から目標状態までの推定距離$\hat{h}(x)$ を示すヒューリスティック関数 (例えば目標状態までのユーグリッド距離) を用いることができる．

2.2 RTA*

マルチエージェント探索の視点から見ると，A*は単一エージェントが目標状態に至る経路をあらかじめ求めてから移動を行うオフライン探索と考えることができる．A*は最適解を保証するが，問題のサイズに応じて指数的な計算量を要するために大きな探索空間を持つ問題に適用することは困難であった．Korf は以下に示すように，定数時間の先読み探索と移動を交互に行うことにより，最適解は保証できないけれども計算量を削減することのできる単一エージェントによるオンライン探索手法として実時間 A* (RTA*) を提案した [5]．

先読み探索フェーズ　現在の状態 x に隣接する状態の集合を $N(x)$ とし，全ての $y \in N(x)$ について，y を経由して目標状態に至る場合の x の評価値 $\hat{f}(x,y) = \hat{f}(y) + c(x,y)$ を計算する．ここで，$\hat{f}(y)$ は yから先読み深さ d までの探索結果をもとに次のように計算する．

$$\hat{f}(y) = \min_{w \in W(y,d)} \{\hat{h}(w) + c'(y,w)\}$$

ただし，$W(y,d)$ は yから深さ d の先読み探索の最先端の状態の集合とし，$c'(y,w)$ は yから wまでのその時点で知られている最適な経路の距離とする．

移動フェーズ　$\hat{f}(x,y') = \min_{y \in N(x)} \hat{f}(x,y)$ となる隣接状態 y'(複数存在するとき，ランダムに選択) へ移動し，$\hat{h}(x)$ の値を二番目に最小な $\hat{f}(x,y'') = \min_{y \in N(x)-\{y'\}} \hat{f}(x,y)$ に更新する．[1]

一般に実時間探索ではエージェントは同じ状態を何度も通過するループに陥る可能性がある．しかしながら RTA*では，エージェントがループに陥ったとしても，同じ状態に到達するたびにその状態の推定距離の値を単調増加させるので，ループ上の全ての状態の推定距離 $\hat{h}(\cdot)$ は単調に増加し，いずれエージェントはループから抜け出すようになる．Korf は目標状態がすべての状態から到達でき，正の移動コストと有限な値を返すヒューリスティック関数をもつ有限な状態空間グラフにおいて，RTA*の完全性を証明している [5]．

2.3 マルチエージェント実時間探索

RTA*で解の質を改善するためには先読み探索フェーズにおいて先読み深さを増大すればよいが，計算量は先読みの深さに対して指数的に増加するという問題点が

[1] $\hat{h}(x)$ 更新の手法には最小の $\hat{f}(x,y')$ にする LRTA*型 [5] と，二番目に小さい $\hat{f}(x,y'')$ にする RTA*型がある．RTA* 型は $\hat{h}(x)$ の評価値としては過大評価となるがエージェントの後戻りの回数は減少するという一長一短がある．3. で提案する組織化手法では RTA*型と LRTA*型を統合した手法を用いている [8]．

ある．それに対し，Knight はエージェント数を増加させることにより解の質を改善させるマルチエージェント探索手法を提案し，その有効性を示した [3]．

Knight の提案したマルチエージェント実時間探索では，エージェントはそれぞれ自律的に先読み深さ 1 で RTA*を実行する．最小評価値を持つ移動候補が複数存在するときには，エージェントはランダムに移動先を選択する．したがって，エージェント数を増加させれば，解の質は確率的に改善される．RTA*において探索時間は，先読み深さの増大に対して指数的に増大するという性質があったが，エージェント数の増加に対しては線形にしか増大しないという有利な性質がある．

3 組織化手法

Knight のマルチエージェント実時間探索におけるランダムな移動候補選択は，各エージェントを探索空間にランダムに分散させることにつながるが，エージェントの探索経路が重複することを避けることができない．このような探索経路の重複は，その冗長性からエージェントの群としての性能を低下させることになる．そこで本研究では，エージェントを組織化して群としての性能を向上させる手法を提案する．エージェントは深さ 1 の先読み探索を行い，移動フェーズは以下のように変更する．

移動フェーズ エージェント i は移動候補集合 $M = \{y_m | \hat{f}(x_i, y_m) = \min_{y \in N(x_i)} \hat{f}(x_i, y)\}$ から次のように移動先 y'(複数存在するとき，ランダムに選択) を決定する．

$$\begin{cases} D(y') = \max_{y_m \in M} D(y_m) \text{ となる } y' \text{を選択する．} \\ \quad \text{if } \forall y_m : D(y_m) < R(x_i) \\ D(y') \geq R(x_i) \text{ となる } y' \text{を選択する．} \\ \quad \text{otherwise} \end{cases}$$

ここで，$D(y)$ は最も近くに存在するエージェントとの間の距離 $\min_{j \in A - \{i\}} \hat{d}(y, x_j)$ である．ただし，A はエージェントの集合，x_j はエージェント jの存在する現在の状態，$\hat{d}(y_m, x_j)$ は状態 y_mから状態 x_jまでの推定距離とする．

探索過程におけるエージェント組織は反発係数 Rの値により決定される．エージェント i の現在の状態 x_iにおける反発係数は $R(x_i) = \frac{\alpha \times \hat{h}(x_i)}{\hat{h}(x_s)}$として計算される．ただし，$x_s$は初期状態とする．この反発係数はエージェントが初期状態に存在するとき，最も大きくなり，目標状態に近づくにつれて小さくなるように工夫している．この結果，探索初期において，各エージェントは互いに離れ，探索経路の重複を避けるようになる．そして，目標状態へ近づくにつれて反発は弱くなり，目標状態へ収束する．また，パラメータαを変化させることにより，反発の強さを調整できるようにしている．

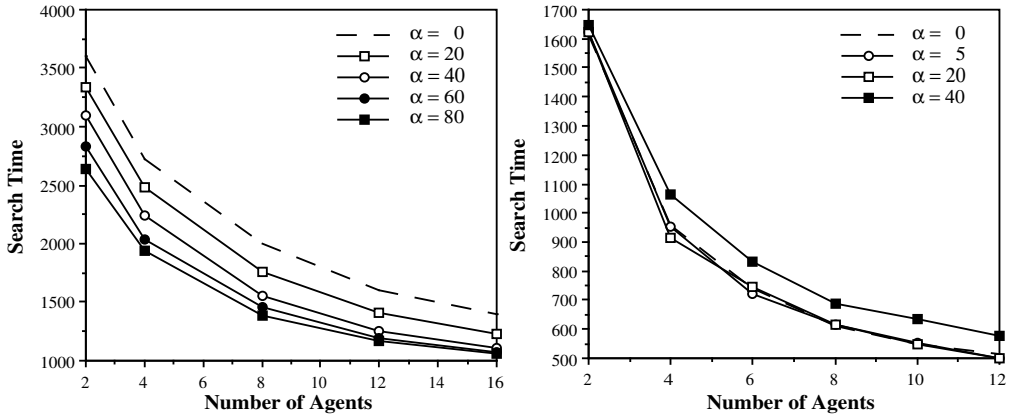

(a) 迷路問題 (b) 15パズル

図 1 マルチエージェント RTA*における組織化の効果

4 評価実験

マルチエージェント実時間探索におけるエージェント組織化手法の性能を評価するために，格子状の迷路探索問題 [1] と 15 パズル問題 [4] を用いた評価実験を行なった．エージェントが更新する$\hat{h}(\cdot)$は全エージェントにより共有されているとする．また，エージェントは並列に動作し，1 マス移動する毎に 1 単位時間かかると仮定している．本実験で探索時間とは，最初に目標状態に到着したエージェントの移動回数 (サイクルを含む) を意味している．$\hat{h}(\cdot)$ の初期値と$\hat{d}(\cdot,\cdot)$ には迷路探索問題ではユークリッド距離，15 パズル問題ではタイル間のマンハッタン距離の総和を用いている．また，ランダムな選択が探索結果に影響を与えるため，1 題を 100 回実行してその平均値を取った．迷路探索問題ははランダムに発生させた 100 題の問題 (迷路のサイズは 120×120 で障害物の比率は 40%)[2]，15 パズルでは [4] の 100 題の内，9 題の問題[3]を解いた平均値である．実験結果を図 1に示す．Knight の手法を用いた結果を点線 $(\alpha = 0)$ で示す．横軸はエージェント数，縦軸は探索時間である．

迷路探索問題は組織化を行い反発係数を大きくすれば，Knight の手法より良い結果が得られているが，15 パズルでは反発係数が大きくなると Knight の手法より性能が悪化するという対照的な結果が出ている．

[2]解の存在するもののみを選択している．

[3]問題の難度を配慮して上級 3 問，中級 3 問，下級 3 問を選択している．

5 考察

マルチエージェント実時間探索における組織化手法の効果は推定凹部 [2] を用いて説明できる．推定凹部とは直観的に，目標状態への推定距離の局所的な凹みである．実時間探索を行なうエージェントは単純に最小な評価値を持つ状態を選択し，移動を続けるので，容易に推定凹部の底へ移動してしまう．推定凹部に陥ったエージェントは推定凹部の各状態の推定距離$\hat{h}(\cdot)$の更新を繰り返し，推定凹部を埋めなければそこから抜け出すことはできない．迷路探索問題は，壁の存在が壁の向こう側にある目標状態に対して推定凹部を作るため，問題空間の至る所で推定凹部が形成されているといえる．それに対して，15 パズル問題では迷路探索問題のような深い推定凹部がほとんど現れず，小さな凹みが広い範囲に分散しているといえる．

Knight の手法では，エージェントはそれぞれランダムに経路を選択するので，提案した組織化手法に比べれば比較的集団として行動しているといえる．したがって迷路探索の場合は多くのエージェントが集団として推定凹部の底へ吸い込まれてしまう．しかしながら，エージェントを互いに反発させる組織化手法ではエージェントはそれぞれ独立に移動するので，推定凹部に陥らないような経路を選択するエージェントの数は多くなる．したがって，迷路探索問題の場合，組織化手法は有効であるといえる．

しかし 15 パズルでは深い推定凹部は少なく，小さな凹みを埋めながら目標状態に向かって行けばよい．その際にはエージェントがばらばらで行動するよりも，目標に向かって協力して凹みを埋めて行くほうが効果的である．すなわち，集団的に行動して，あるエージェントが行なった推定距離の更新を他のエージェントが利用できる方が望ましい．したがって，エージェントを互いに反発させる組織化は 15 パズルに対しては効果が期待できないといえる．

6 まとめ

マルチエージェント実時間探索におけるエージェント組織化手法を提案し，迷路探索問題と 15 パズル問題を用いてその評価を行なった．エージェント間の反発に基づく組織化手法は，迷路探索問題において良い結果を示したが，15 パズル問題においては，反発を大きくすると性能が悪化した．その原因は推定凹部の深さと分布の違いによるものであることを示した．

参考文献

[1] Toru Ishida and Richard E. Korf. Moving target search. In *Proceedings of the 1991 Inter-*

national Joint Conference on Artificial Intelligence, pp. 204–210, 1991.

[2] 石田亨. 実時間両方向探索. マルチエージェントと協調計算 II, pp. 121–135. 近代科学社, 1993.

[3] Kevin Knight. Are many reactive agents better than a few deliberative ones? In *Proceedings of the 1993 International Joint Conference on Artificial Intelligence*, pp. 432–437, 1993.

[4] Richard E. Korf. Depth-first iterative-deepening: An optimal admissible tree search. *Artificial Intelligence*, Vol. 27, pp. 97–109, 1985.

[5] Richard E. Korf. Real-time heuristic search. *Artificial Intelligence*, Vol. 42, pp. 189–211, 1990.

[6] Judea Pearl. *Heuristics*. Addison-Wesley, Reading, Massachusetts, 1984.

[7] 白井良明, 辻井潤一. 人工知能. p. 46, 岩波書店, 東京, 1982.

[8] 寺西憲一. マルチエージェント実時間探索における組織化手法に関する研究. 大阪市立大学工学研究科電気工学専攻修士論文, 1995.