

灰色分析型自律エージェント協調形成手法への一提案

Proposal for the Coalition Formation Method of Autonomous Agent Based on Grey Analysis

水谷 晃三[†]
Kozo Mizutani
小林 俊裕[†]
Toshihiro Kobayashi
山口 大輔[†]
Daisuke Yamaguchi

赤羽根 隆広[†]
Takahiro Akabane
池本 悟[†]
Satoru Ikemoto
永井 正武[†]
Masatake Nagai

1. はじめに

マルチエージェントシステムにおいては、タスクを効率的かつ効果的に分配してシステム全体の品質を高めることが重要である。個々のエージェントやシステム全体に関する情報を効率的に収集する手法^[1]や、収集された情報に基づくエージェント協調形成手法^[2]が既に提案されてきた。

収集される情報は、個々のエージェントや環境に応じて値の意味が異なる場合があり、システムの設計段階において統一的に定義してしまったのが一般的である。しかし全体の柔軟性を欠く恐れがあり、自律エージェントの有効性を活かすことができない場合がある。そこで本論文では、灰色理論に基づく灰色分析の導入による効果的なエージェント協調形成手法を提案する。統括型および分散型の導入手法により、柔軟性と効率性を両立する。

2. 基礎理論

2.1 灰色理論^[3]

対象とする情報が完全既知である状態を「白色」とし、完全未知である状態の場合を「黒色」と定義する。灰色理論では「灰色」を白色と黒色の中間状態の相対値であると定義し、情報が部分既知または部分未知である状態としている。

例えばマルチエージェントシステム M において、 N 個のエージェント $a_n (n=1, 2, \dots, N)$, $a_n \in M$ が存在すると仮定する。各エージェントにはパラメータ $x_n = \{x_n(1), x_n(2), \dots, x_n(k_n)\}$ があり、各々の振舞いや協調関係の形成に応じて変化する。パラメータの数 k_n は個々のエージェントにごとに異なり、特定のパラメータ $x_n(j)$, $(j=1, 2, \dots, k_n)$ が全てのエージェントに存在するとは限らないとする。ここで、各エージェントの多忙度 $x_n(Busyness)$ を収集したとき、その集合 $X(Busyness)$ は部分既知な情報となり灰色である。すなわち、すべてのエージェントが $x_n(Busyness)$ パラメータを持ち、かつ正確な通知義務が定義されていない限り、 $X(Busyness)$ は白色になることはない。時間的概念を考慮すれば、情報収集を完了した時点で、各エージェントのパラメータが既に変化している可能性もある。よって、収集された情報は常に灰色であると捉えることができる。

2.2 灰色分析

灰色分析は数列が持つ順序性に着目した分析手法であり、局部型灰色分析と全体型灰色分析がある。本論文では、局部型灰色分析を用いた自律エージェント協調形成手法を提案する。

灰色分析では、対象となる原始数列 x を次のように定義する。

$$x = \{x(1), x(2), \dots, x(k)\} \quad (1)$$

ただし、 $x(j) \in x \Rightarrow j \in K$, $K = \{1, 2, \dots, k\}$ である。

局部型灰色分析においては、分析対象とする N 個の比較数列 x_n ($n = 1, 2, \dots, N$) と、分析基準とする参照数列 x_0 を用意する。

† 帝京大学大学院理工学研究科, Science and Engineering,
Graduate School of Teikyo University

次式より各比較数列と参照数列の差 $\Delta_{0n}(j)$ を算出する。

$$\Delta_{0n}(j) = |x_0(j) - x_n(j)| \quad (2)$$

次に極最小値 Δ_{\min} と極最大値 Δ_{\max} を求める。

$$\left. \begin{array}{l} \Delta_{\min} = \min_{\forall n \in N} \min_{\forall j \in k} \{\Delta_{0n}(j)\} \\ \Delta_{\max} = \max_{\forall n \in N} \max_{\forall j \in k} \{\Delta_{0n}(j)\} \end{array} \right\} \quad (3)$$

得られた結果から、 $\Delta_{0n}(j)$ に対する灰色関連係数 γ を算出する。

$$\gamma(x_0(j), x_n(j)) = \frac{\Delta_{\min} + \zeta \Delta_{\max}}{\Delta_{0n}(j) + \zeta \Delta_{\max}} \quad (4)$$

ここで ζ は弁別係数と呼ばれ、 $\zeta \in [0, 1]$ である。適応系に応じて調整可能とされるが通常 $\zeta = 0.5$ とする。

最後に、式(5)によって灰色関連度 Γ_{0n} を算出する。

$$\Gamma_{0n} = \sum_{j=1}^k \beta_j \gamma(x_0(j), x_n(j)) \quad (5)$$

ただし、 β_j はパラメータ j の重みであり $\sum_{j=1}^k \beta_j = 1$ とする。

算出された Γ_{0n} は、参照数列 x_0 に対する比較数列 x_n の関連度合いを示している。

3. 灰色分析型エージェント協調形成手法

3.1 基本概念

タスク依頼元のエージェント A_{master} が、エージェント群 M から依頼先エージェントを選択する場合を想定する。各エージェント a_n には、パラメータ数列 x_n として多忙度 $x_n(Busyness)$ 、タスク達成率 $x_n(Achievement)$ 、短時間当たりのタスク処理性能 $x_n(Ability)$ を必ず保持するものとする。 A_{master} が、タスク依頼の条件として数列 $x_0 = \{x_0(Busyness), x_0(Achievement), x_0(Ability)\}$ を持つ場合、各エージェントのパラメータ x_n に対し、 x_0 を参照数列とする局部型灰色分析を行なうことができる。分析の結果、灰色関連度 Γ_{0n} が最も大きいパラメータを持つエージェント a_n に対してタスク依頼を行う。つまり、 A_{master} の条件に対して最も関連性の高いパラメータをもつエージェントをタスク依頼先として選択する。なお、数列 x_n のパラメータはエージェントシステムにおいて任意であるほか、 x_0 に応じてパラメータを随時構成することもできる。

3.2 統括型分析処理による協調形成

統括型分析処理による協調形成手法では、式(2)～(5)の灰色局部型分析処理をタスク依頼元のエージェント A_{master} が行う。その手順は次のとおりである。

- ① A_{master} からマルチキャスト方式でパラメータ通知要求を送信
 - ② 各エージェント a_n は自身のパラメータ数列 x_n を返信
 - ③ A_{master} は、受信したパラメータ数列 x_n を比較数列、タスク選択条件 x_0 を参照数列として灰色分析
 - ④ $\max\{\Gamma_{0n}\}$ となるエージェント a_n に対してタスクを依頼
- ステップ①において、 A_{master} はタスク選択に必要なパラメータだけを返信するように、各エージェントに指定する

ことができる。統括型では、タスク依頼基準に関する情報が保護されるため、協調関係に一定の階層性を維持することができる。

3.3 分散型分析処理による協調形成

分散型分析処理による協調形成手法では、式(2)の計算を各エージェントで分散的に行い、式(3)以降をタスク依頼元エージェントで行う手法である。以下に具体的な手順を示す。

- ① A_{master} からマルチキャスト方式で、タスク依頼基準となる数列 x_0 を送信
- ② a_n は、受信した x_0 と自身のパラメータ数列 x_n との差 Δ_{0n} を算出し、 A_{master} に返信
- ③ A_{master} は、受信した Δ_{0n} から灰色関連度 Γ_{0n} を算出
- ④ $\max\{\Gamma_{0n}\}$ となるエージェント a_n に対してタスクを依頼

分散型では局部型灰色分析処理の一部を分散することにより、効率的にタスク選択を行うことができる。統括型と大きく異なるのは、タスク依頼基準 x_0 を各エージェントに公開することである。例えばステップ②において、各エージェントは x_0 の値に応じて意図的に Δ_{0n} を調整することができる。競争的な関係を持つ集団形成に利用可能である。

4. 実験

4.1 実験内容

ステップ単位で同期を行うエージェントシステムを用いて本提案手法の実験と評価を行う。エージェントプラットホームは Aglets2.0.2 を利用し、独自のステップ同期クラスを組む。

A_{master} のタスク依頼条件は $x_0=\{0, 0, 1\}$ 固定とする。タスク依頼先エージェントの $x_n(Busyness)$ はタスク実行中に 1 となり、新しいタスク受付を破棄する。 $x_n(Achievement)$ はタスクを完了すると 1 割増え、タスクを破棄すると 1 割減少する。 $x_n(Ability)$ の値は全て 0.9 固定とし、活動中に変化することはない。以下、2 つの実験パターンをそれぞれ 3 回行い、平均結果をグラフにまとめる。

4.2 実験結果

図 1 は、タスク依頼先エージェントの数 $N=50$ 、タスク数 $tCount=50$ とし、1タスクのステップ数 $TaskStep$ に応じた変化をまとめたものである。全タスク終了までの総ステップ数と、実際にタスクを実行したエージェントの数を示している。図 2 は $tCount=50, TaskStep=1000$ とし、タスク依頼先となるエージェントの数 N を変化させた時の、総ステップ数と実際にタスクを実行したエージェントの数である。

5. 考察

実験結果より、分散型のほうが統括型に比べて効率良くタスクが分散されていることが分かる。例えば図 1において、統括型では $TaskStep=25000$ の時に 31、分散型では 40 のエージェントがタスクを実行している。しかし $TaskStep=50000$ では、両手法とも 50 のエージェントがタスクを実行しており先の結果と矛盾する。この現象は、本実験条件における $tCount$ が限界であることを示している。実際、他の条件を変えずに $tCount=51$ としたとき、 $TaskStep=50000$ では破棄されるタスクが出現することを確認している。

図 2からは、エージェントの数が多くなるほどタスク依頼の分散性が減少していることが分かる。灰色分析に要するステップが多くなり、依頼先を決定するまでの間に時間がかかるためである。依頼するタスクステップ数が少なすぎる場合においても同様である。

本論文では、実験結果を明確にするため各エージェントの $x_n(Ability)$ は固定としたが、環境に応じて変化するよう

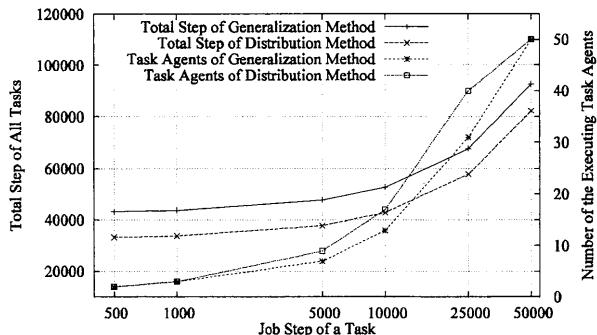


図1 タスクのステップ数に応じた変化

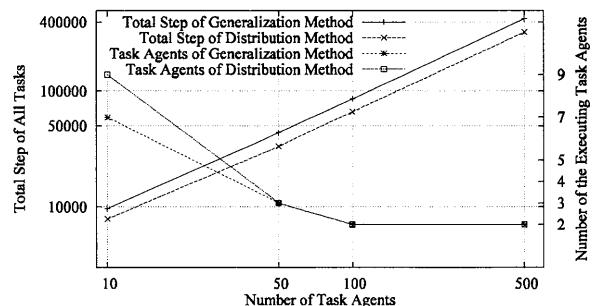


図2 エージェント数に応じた変化

な状況を想定する必要がある。1 つのエージェントが同時に実行できるタスク数を考慮したり、複数の A_{master} が同時に存在したりする場合についても評価が必要である。このような複雑な状況では、効率をさらに向上させるためにエージェントのグループ化や予測技術の導入が望まれる。グループ化については、灰色クラスター分析^[3,4]の適用が考えられる。灰色予測や灰色意思決定^[3,5]なども知られており、本提案の協調形成手法を含めて、灰色理論の同一処理体系で実装することができる。データ構造やアルゴリズムを積極的に再利用できることから、軽量なエージェントの実現が可能である。

6. おわりに

本論文では、灰色理論に基づく灰色分析を適用するエージェントの協調形成手法について述べた。統括型と分散型の 2 手法を提案し、それぞれの特徴を実験により確認した。

今後は、他の協調形成手法との比較と灰色クラスター分析によるグループ化、および灰色予測と意思決定法の導入により、複雑な条件下における評価を行っていく。

参考文献

- [1] Reid G. Smith, "Contract Net Protocol: High-Level Communication and Control in a Distributed Problem Solver," IEEE Transactions on Computers, Vol.C-29, No.12, pp.1104-1113, 1980.
- [2] 加藤貴司, 木下哲男, 白鳥則郎, "マルチエージェントの集団形成方式," 電子通信学会論文誌, Vol.J84-D-I, No.2, pp.173-182, Feb.2001.
- [3] 永井正武, 山口大輔, 灰色理論と工学応用方法入門, 共立出版, 2004.
- [4] 山口大輔, 小林俊裕, 水谷晃三, 永井正武, "灰色理論を応用した階層的クラスター分析法の提案," 情報処理学会研究会報告, Vol.2004, No.10, AL-93-11, Jan.2004.
- [5] 鄧聚龍(著), 趙君明, 北岡正敏(訳), 灰色理論による予測と意思決定, 日本理工出版会, 1999.