

群れ行動と縄張り行動の相転移モデル Phase Transition Model of Swarm Behavior and Territorial Behavior

澤田 樹[†] 松本 倫子[†] 吉田 紀彦[†]
Tatsuki Sawada Noriko Matsumoto Norihiko Yoshida

1. はじめに

群れ行動や縄張り行動といった、生物集団の知的な振る舞いに着想を得た数理モデルが数多く提案されている。

自然界における生物の群れとは、多数の同種個体が集まり、共通の指向性を示す集団のことである。群れを成すことにより、特定の環境下における最適化の能力を示すことが知られている [1]。このような群れ行動の知能に着想を得た一連の数理モデルは、群知能と呼ばれる。代表的な群知能アルゴリズムとして、鳥や蜂の採餌行動をモデル化したエージェントの集団が、座標空間上を動き回り大域的最適解に集まる Particle Swarm Optimization (PSO) や Artificial Bee Colony Algorithm (ABC) などが挙げられる [2]。

他方、縄張りは、生物の個体あるいは群れが同種の他の個体を排除することによって、空間を互いに重ならない領域に分割する。生物の縄張りの空間分割パターンは、均一な理想環境下において多角形様になることが知られている [3]。縄張りの性質を利用した数理モデルとして、被覆制御が挙げられる。このモデルでは、モバイルセンサが、自身とその近傍の局所的な位置情報のみを用いて空間内を移動し、大域的な最適配置問題を解決する [4]。

群れ行動と縄張り行動の数理モデルを比較すると、どちらも自己駆動するエージェントが空間を探索する点は共通しているが、前者は協調による最適解の発見、後者は空間分割による最適配置といったように、その挙動や問題解決能力は異なる。このような振る舞いを使い分ける自然界の事例として、メダカなどの一部の魚類は、周囲の環境の広さや生息密度に応じて群れ行動と縄張り行動を相互に移行することが知られている [5]。

従来の研究では、群れ行動と縄張り行動は異なる現象として個別にモデル化され、それらの行動が発現する統一的な因子はほとんど考えられてこなかった。しかし、群れ行動と縄張り行動のような、異なる問題解決能力を持った集団の振る舞いが、どのような原理に基づいて生じ得るかを理解することは、生物の持つ環境に対する高い適応性を工学に取り入れ、より汎用的な人工知能モデルおよび数理最適化法を設計していく上で重要であると考えられる。

関連研究として、Vicsek モデルがある。これは、生物を自己駆動する粒子としてモデル化し、無秩序状態から群れ行動への移行を、移動方向の決定に際するノイズによる相転移現象として扱えるものである [6]。本研究では、群れ行動と縄張り行動が、近傍の個体数のような環境的変数による相転移現象として扱えるようなモデルを提案する。

2. モデル

探索空間 $f(\vec{x})$ 上に N 個のエージェントをランダムに配置する。各エージェント $i = 1, \dots, N$ は、以下に示すアルゴリズムに従って、速度の更新を終了条件まで繰り返す。

[†] 埼玉大学, Saitama University

i. 近傍エージェントの観測:

エージェント i は周囲の半径 R より内に存在するエージェント群を近傍集合 N_i として観測する。また、自身の周囲の半径 $R_{av} < R$ より内に存在するエージェント群を、衝突を回避すべき集合 N_i^{av} として観測する。

$$N_i = \{j | j \neq i \wedge |\vec{x}_j - \vec{x}_i| < R\} \quad (1)$$

$$N_i^{av} = \{j | j \neq i \wedge |\vec{x}_j - \vec{x}_i| < R_{av}\} \quad (2)$$

ii. 探索空間の評価:

次式を用いて、探索空間 $f(\vec{x})$ の値を正の利得 $fit(\vec{x})$ に変換する。

$$fit(\vec{x}) = \begin{cases} \frac{1}{1 + f(\vec{x})}, & f(\vec{x}) \geq 0 \\ 1 + \text{abs}(f(\vec{x})), & f(\vec{x}) < 0 \end{cases} \quad (3)$$

このような正值への変換は、ABC において最小化問題を解く場合に用いられる [2]。これをもとに、次の評価関数

$$\text{eval}(\vec{x}, n) = \frac{w}{(n+1)^d} fit(\vec{x}) \quad (4)$$

を用いて、自身の座標 \vec{x}_i に対する評価値 $\text{eval}(\vec{x}_i, |N_i|)$ を求める。なお、 n は近傍数、 $w > 0$ は重み係数、 $d \geq 0$ は利得の割引強度である。この評価関数は、近くにいる競合相手が多くなるほど、自身の獲得できる資源が減少するというアイデアに基づく。

iii. 速度の更新:

エージェント i は、より評価値の高い座標を目指して、近傍の評価値を重みとする重心座標への加速度 \vec{a}_i^g を生じる。また、エージェント同士が過剰に接近するのを防ぐため、衝突を回避する加速度 \vec{a}_i^{av} も加える。それぞれの加速度を係数 c_g 、 c_{av} で正規化し、線形和をとったものを \vec{a}_i とする。これを現ステップにおける速度 \vec{v}_i に加え、関数 $\vec{V}(\vec{v})$ を用いて最大速度 V_{\max} を超えないように制限したものを、次ステップにおける速度 \vec{v}_i^{next} とする。

$$\vec{a}_i^g = \frac{\sum_{j \in N_i} \text{eval}(\vec{x}_j, |N_j|) \cdot \vec{x}_j}{\sum_{j \in N_i} \text{eval}(\vec{x}_j, |N_j|)} - \vec{x}_i \quad (5)$$

$$\vec{a}_i^{av} = \sum_{j \in N_i^{av}} \frac{\vec{x}_j - \vec{x}_i}{|\vec{x}_j - \vec{x}_i|} \quad (6)$$

$$\vec{a}_i = \frac{c_g}{|\vec{a}_i^g|} \vec{a}_i^g + \frac{c_{av}}{|\vec{a}_i^{av}|} \vec{a}_i^{av} \quad (7)$$

$$\vec{v}_i^{\text{next}} = \vec{V}(\vec{v}_i + \vec{a}_i) \quad (8)$$

$$\vec{V}(\vec{v}) = \min\left(\frac{V_{\max}}{|\vec{v}|}, 1\right) \cdot \vec{v} \quad (9)$$

3. 実験

探索空間 $f(\vec{x})$ において、エージェント数 $N = 200$ ，最大速度 $V_{\max} = 0.05$ ，認識半径 $R = 2.0$ ，衝突回避する半径 $R_{av} = 0.2$ ，重み係数 $w = 100000$ ，重心に向かう強さ $c_g = 5$ ，衝突回避の強さ $c_{av} = 10$ ，およびエージェントの初期配置を区間 $[-5.12, 5.12]^2$ 内でランダムに与え，10000 ステップの実験を行い，割引強度 d の違いによってエージェント全体がどのように振る舞うかを観察した。

(A) 群れ行動の発現と最適化特性

$d = 0$ とし，表 1 に示すテスト関数に対してそれぞれ実験を行った。これらの関数は，Eberhart らが PSO のベンチマークに用いたものである [7]。結果，エージェントが 1 つの集団を形成し，大域的最適解 f_{\min} へ指向する群れ行動が発現した。最終的に，図 1 下段のような f_{\min} を中心とする集まりを形成した。これにより，既存の群知能アルゴリズムと同様，最適化の能力を持つことが確認された。

表 1：テスト関数 [7]

名称	式
Sphere	$f_1(\vec{x}) = x_1^2 + x_2^2$
Rosenbrock	$f_2(\vec{x}) = 100(x_2 - x_1^2)^2 + (x_1 - 1)^2$
Rastrigin	$f_3(\vec{x}) = x_1^2 + x_2^2 - 10(\cos 2\pi x_1 + \cos 2\pi x_2) + 20$
Ackley	$f_4(\vec{x}) = 20 + e - 20e^{-0.2\sqrt{\frac{1}{2}(x_1^2 + x_2^2)}} - e^{\frac{1}{2}(\cos 2\pi x_1 + \cos 2\pi x_2)}$

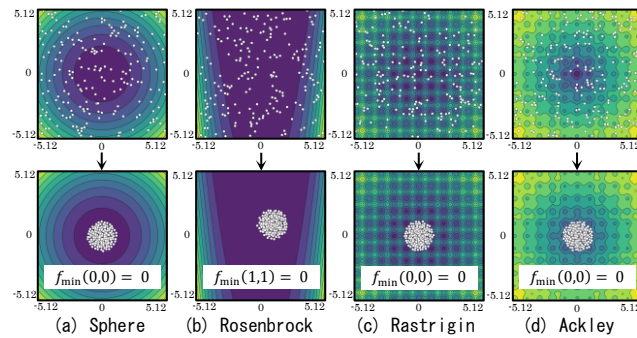


図 1：大域的最適解に集まるエージェントの群れ

(B) 縄張り行動の発現と空間分割特性

$d = 5$ とし， $f(\vec{x}) = f_1(\vec{x})$ に対して実験を行った。結果，図 2 (a) のように，複数のエージェントの集団が空間を分割する縄張り行動が発現した。この空間分割のパターンは，1 つの集団が大域的最適解を占有し，その周囲を他の複数の集団が囲む多角形様となっており，現実世界の縄張りのパターン [3] との類似が見られた。

あるエージェントにおいて，自身あるいは近傍のうち，評価値が最も大きいエージェントを best と呼ぶことにする。




図 2：クラスタの空間分割

各エージェントと自身の best を辺で繋ぐと，図 2 (b) のように 1 個の best に複数のエージェントがぶらさがる構造が現れた (ただし，エージェントは丸，1 個以上の他エージェントから best に選ばれたエージェントは星で表す)。図 2 (a) で形成された局所的な集団は，図 2 (c) に示すように 1 個の best を中心とするまとまりに対応していたことから，このまとまりをクラスタと定義する。よって，以降はクラスタの数と best の数が一致すると仮定する。

(C) 群れ行動と縄張り行動の相転移

$f(\vec{x}) = f_1(\vec{x})$ とし， d を区間 $[0, 20]$ 内で変化させたとき (刻み幅は，区間 $[1, 2]$ 内で 0.1，それ以外で 0.25 とした) の， d に対するクラスタの数の平均を調べた。1 回の試行では，初め 9000 回の空ループを実行した後，残りの 1000 ステップ内での best の最小総数をクラスタの数として数えた。各 d に対して 10 回の試行を行った平均を求めた結果，図 3 のようになった。 $d = 0$ から単一のクラスタを形成し，群れ行動の様相を呈していたものが， $d = 1.5$ を境界として急激に縄張り行動の様相を呈し，境界値を $d_0 = 1.5$ とする相転移が確認された。




図 3：割引強度 d に対するクラスタ数の平均

4. おわりに

本稿では，エージェントの近傍数の増加に伴って利得が割引かれるモデルを考案した。利得の割引強度を大きくすると，単一の集団を形成する群れ行動から，複数の集団が空間を分割する縄張り行動への相転移が起こることを示した。今後は，最適化特性の群知能アルゴリズムとしての応用可能性と，空間分割特性の被覆制御への応用可能性を視野に入れ，モデルの改良を行っていく予定である。

参考文献

- [1] S. Goss, S. Aron, J. D. Deneubourg, J. M. Pasteels: "Self-organized Shortcuts in the Argentine Ant", *Naturwissenschaften*, Vol. 76, pp. 579-581, 1989.
- [2] M. N. Ab Wahab, S. Nefti-Meziani, A. Atyabi: "A Comprehensive Review of Swarm Optimization Algorithms", *PLoS One*, Vol. 10, No.5, 2015.
- [3] 長谷川 政美: "なわばりによる空間分割のパターンについて—なわばり形成の幾何学的統計モデル—", *応用統計学*, Vol. 5, No. 2, 1976.
- [4] S. Martinez, J. Cortès, F. Bullo: "Motion coordination with distributed information", *IEEE Control System Magazine*, Vol. 27, No. 4, pp. 75-88, 2007
- [5] 川那部 浩哉: "アユの社会構造と生産：生息密度と関連づけて"，*日本生態学会誌* Vol. 7, No. 4, pp. 131-137, 1957.
- [6] 平岡 喬之: "自己駆動粒子系の動力学：群集運動を中心に"，*ワーキングペーパーシリーズ人工社会研究*, No.44, 2014.
- [7] A. Stacey, M. Jancic, I. Grundy: "Particle Swarm Optimization with Mutation", 2003 IEEE Congress on Evolutionary Computation, pp. 1425-1430, 2003.