

役割分担を行うミツバチコロニー最適化

白崎 雄大[†] 下村 将[†] 上手 洋子[†] 西尾 芳文[†]

[†] 徳島大学工学部 〒770-8506 徳島県徳島市南常三島町 2-1
E-mail: †{shirasaki, s-sho, uwate, nishio}@ee.tokushima-u.ac.jp

あらまし 本研究で我々は新しいミツバチコロニー最適化 (Honeybee Colony Optimization: HCO) として、役割分担を行うミツバチコロニー最適化 (Honeybee Colony Optimization with Role and Responsibility: HCOR&R) を提案する。HCOR&R は、グローバルサーチを行う探索バチとローカルサーチを行う派遣バチという様に現実のミツバチと同様に役割分担を行う。HCOR&R を巡回セールスマン問題 (Traveling Salesman Problem: TSP) に適応し、従来の HCO より効果的な結果を得ることを確認する。

キーワード 最適化, 巡回セールスマン問題, ミツバチ, ローカルサーチ

Honeybee Colony Optimization with Role and Responsibility

Yudai SHIRASAKI[†], Sho SHIMOMURA[†], Yoko UWATE[†], and Yoshifumi NISHIO[†]

[†] Department of Electrical and Electronic Engineering, Tokushima University
2-1 Minami-Josanjima, Tokushimashi, Tokushima, 770-8506, Japan
E-mail: †{shirasaki, s-sho, uwate, nishio}@ee.tokushima-u.ac.jp

Abstract In this study, we propose a new Honeybee Colony Optimization (HCO) method; Honeybee Colony Optimization with Role and Responsibility (HCOR&R). In HCOR&R, Role and Responsibility is performed like an actual honeybee like the search-bee who performs a global search, and recruit-bee who performs a local search. We apply HCOR&R to Traveling Salesman Problems (TSPs) and confirm that HCOR&R obtains more effective results than the standard HCO.

Key words Optimization, Traveling Salesman Problem, Honeybee, Local Search

1. ま え が き

巡回セールスマン問題 (Traveling Salesman Problem: TSP) は都市の集合と各 2 都市間の移動コストが与えられたとき、全ての都市をちょうど一度ずつ巡り出発地に戻る巡回路のコストすなわち総移動距離が最小のものを求める組合せ最適化問題であり、都市数が増えるに従って計算量が爆発的に増加することから非常に困難な問題とされている。TSP の解法として、アントコロニー最適化 (Ant Colony Optimization: ACO) [1], [2] や粒子群最適化 (Particle Swarm Optimization: PSO) [3] などの最適化手法が用いられる。これらは現実の昆虫や鳥などの生物学的なメカニズムを応用した最適化アルゴリズムであり総じて群知能と呼ばれている。

本研究では、ミツバチの採餌行動をモデル化した群知能の一種であるミツバチコロニー最適化 (Honeybee Colony Optimization: HCO) [4]-[6] を用いた TSP の解法として新しいアルゴリズムの提案を行う。現実世界のミツバチの特徴として、役割分担を行う昆虫であり、生まれた瞬間から既に自分の役割

が決定していて一生を与えられた役割通りに行動する。そしてこの特徴は採餌行動の際にもみられる。次に、採餌行動の手順を説明する (図 1 参照)。ミツバチには女王バチや働きバチ、雄バチなどが存在するが採餌行動を行うのは働きバチのみであり、その働きバチの中でも探索バチと派遣バチの 2 種類に分けられる。まず、探索バチはランダムに周囲を探索することで芳香な食料源を探す。そして芳香な食料源を発見すると、探索バチは巣に戻ってその食料源に適切な数の派遣バチを派遣するために尻振りダンス (Waggle Dance) [7] を行なう。この尻振りダンスは、派遣行動とナビゲート行動を組み合わせたものであり、派遣行動は巣で待機している派遣バチに探索結果を伝えることで食料源に適切な数の派遣バチを派遣する役割、ナビゲート行動は巣で待機している派遣バチと誘導したい場所の位置情報 (方向と距離) を共有する役割をそれぞれ持つ。このように 2 種類のミツバチが分担して探索することによって個々で各々に探索するのではなく、集団で広域に渡って緻密な探索を行うことができる。これら役割分担や集団行動は昆虫では珍しいものとされ、それゆえ、社会的な昆虫とも言われている。

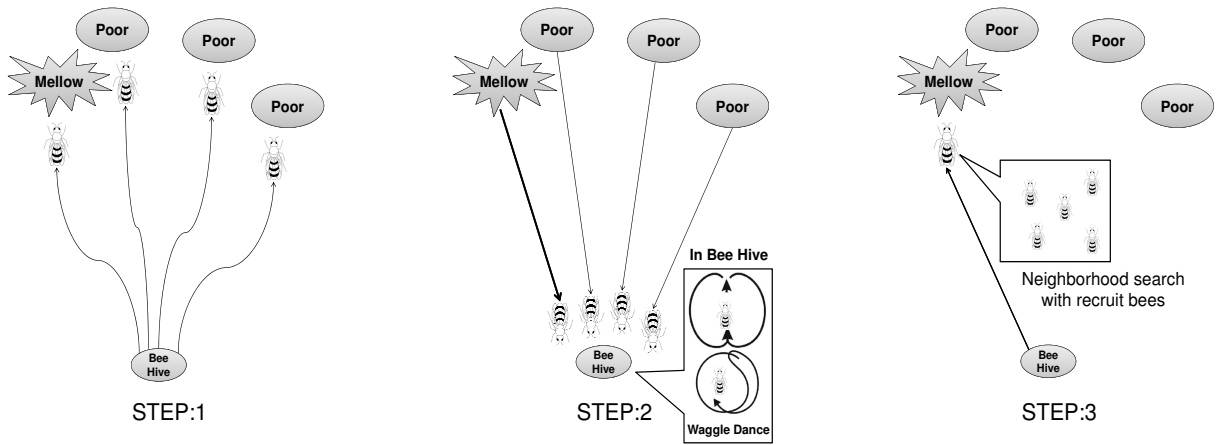


図1 Food foraging behavior of honeybee

HCO では, ”ハチ” と呼ばれる並列的に行動する複数の解が存在し, ハチごとにそれぞれ最適な巡経路リスト: Personal tour List(PL) を持ちより良い経路を発見した際は自身の PL の更新を行う. それとは別に, 全体で PL の情報を共有, 更新した巡経路リスト: Global tour List(GL) を持つ. この2つを使い分けることで HCO は局所解に陥るリスクを下げている. しかし, 都市数が増えるに従って, 計算量が膨大になり部分的に局所解に陥ってしまう問題点がある.

そこで我々は, 現実のハチが行っている役割分担 (探索バチと派遣バチ) の概念を追加した役割分担するミツバチコロニー最適化 (Honeybee Colony Optimization with Role and Responsibility: HCOR&R) を提案する. 従来の HCO では, 全ての解は全都市の巡経路を求めるためにグローバルサーチを行っているが HCOR&R ではそれに加えてローカルサーチも行う. ローカルサーチとは, グローバルサーチと比べて探索都市数を少なくしたものであり, グローバルサーチより細部まで探索できる特徴を持つ. これより, 探索バチ部分的な最適解の情報を複数得ることができ, それらを組み合わせることで最適解への到達が容易となる.

HCOR&R の原理については2章で説明する. 3章では, HCOR&R を2つの TSP に応用し, 従来の HCO と比較することにより HCOR&R の性能を確認する.

2. HCOR&R

通常の HCO と比較した場合, HCOR&R の重要な特徴は, グローバルサーチを行う探索バチとローカルサーチを行う派遣バチの2種類のハチが存在していることである (図2参照).

探索の初期段階において, すべてのハチ M 匹の中で探索バチ $M_g (g = 1, 2, \dots, m_g)$ のみがグローバルサーチを行う. そして, 評価の高かった巡経路を GL 及び PL に記憶, 更新を行っていく. ある期間経過した後 ($t < t_{limit}$), GL を利用しながら派遣バチ M_l はローカルサーチを行う.

$$M_g = M \times R, \quad M_l = M(1 - R) \times \frac{1}{2} \quad (1)$$

R は, M_g と M_l の比率を決定する制御パラメータである. ローカルサーチは, まず全都市の位置情報の平均を取りその中で最も中心近くの数都市の中からランダムで選ばれた都市を共通都市と定める. 共通都市は分割した時にどちらにも含まれるものとする. ローカルサーチを行う派遣バチ M_l は, 最適候補解の巡経路を記憶した GL を用い, それを境目に巡経路を2つに分割する. そして, その情報をグローバルサーチを行う探索バチ m_g に還元している. 情報の還元は, M_l の GL をカウントしていくことで行う. 例えば都市数 $N = 6$ で $GL = \{4, 2, 3, 1, 5, 6, \}$ の時, まず 6×6 の行列を作成する. そして, $\{4$ と $2\}$, $\{2$ と $3\}$, $\{3$ と $1\}$, ..., $\{6$ と $4\}$ の様に GL の隣に隣接している都市をカウントしていく. 4 と 7 の場合, 4 行 7 列と 7 行 4 列にカウントする. ただしこの時, 共通都市に隣接している都市ではカウントしないものとする. これは, ローカルサーチにおける共通都市周辺では局所解に陥っている場合が多いためである.


また一定期間経過やローカルサーチが局所解に陥って改善が見込めない場合, ローカルサーチの初期化を行う. そして再度都市の分割を行うがこのときに, 分割する共通都市を変更させることで分割した時に含まれる都市を変化させ, 局所解に陥る可能性を抑えている. 共通都市の変更方法は, 初期の共通都市とに比較的近い都市がランダムで選ばれる. TSP の N 個の都市集合 S は次式で表される.

$$S \equiv P_1, P_2, \dots, P_N, \quad P_i \equiv (x_i, y_i) \quad (2)$$


都市の座標は0から1に正規化し, P_i は i 番目の都市の場所を表している ($i = 1, 2, \dots, N$).

[Step. 1] (初期化) $t = 0, t_R = 0$ (t_R はローカルサーチの初期化カウント) とする.


[Step. 2] (巡回路の生成) $M (= M_g + M_l)$ 匹の巡経路を生成する. ローカルサーチは $t > t_{local}$ 以降から開始.



(a) グローバルサーチ



(b) ローカルサーチ



(c) ローカルサーチ+グローバルサーチ

図2 HCOR&R の探索方法

$$P_{ij,n}(t) = \frac{[\rho_{ij,n}]^\alpha \cdot [\frac{1}{d_{ij}}]^\beta \cdot [C_{ij}]^\gamma}{\sum_{j \in A_{g,i,n}} [\rho_{ij,n}]^\alpha \cdot [\frac{1}{d_{ij}}]^\beta \cdot [C_{ij}]^\gamma} \quad (3)$$

$$(t > t_{local}) P_{l,ij,n}(t) = \frac{[\rho_{ij,n}]^\alpha \cdot [\frac{1}{d_{ij}}]^\beta}{\sum_{j \in A_{l,i,n}} [\rho_{ij,n}]^\alpha \cdot [\frac{1}{d_{ij}}]^\beta} \quad (4)$$

$\rho_{g,ij,n}$ は n 回目の移動で都市 i から都市 j へツアーリスト ($GL(t)$ or $PL_i(t)$) を用いて移動する確率であり, d_{ij} は都市 i から都市 j の距離の逆数である. $A_{g,i,n}$, $A_{l,i,n}$ は, g, l が n 回目の移動でまだ訪れていない都市集合である. そして, C_{ij} はローカルサーチから得られる局所的な最適解の情報であり, $P_{ij,n}(t)$ でも PL を使用している場合 $\gamma = 0$ とする, α, β, γ は各々の制御パラメータである.

$\rho_{ij,n}$ は,

$$\rho_{ij,n} = \begin{cases} \lambda, & j \in F_{i,n}, |A_{i,n}| > 1 \\ \frac{1-\lambda|A_{i,n} \cap F_{i,n}|}{|A_{i,n} - F_{i,n}|}, & j \notin F_{i,n}, |A_{i,n}| > 1 \\ 1, & |A_{i,n}| = 1 \end{cases} \quad (5)$$

で表される. ($0 \leq \lambda \leq 1$)

[Step. 3] (グローバルサーチ) 巡経路の評価を行う. そして, Waggle Dance に従う確率を求める.

$$P_{fg} = \frac{1}{L_g}, \quad L_g = \text{tour length} \quad (6)$$

$$P_{f_{colony}} = \frac{1}{N_{bee}} \sum_{g=1}^{M_g} P_{fg} GL(t) = \frac{P_{fg}}{P_{f_{colony}}} \quad (7)$$

P_{fg} はハチ g の評価値であり, これは総距離 L_g の逆数である. $P_{f_{colony}}$ は M_g 匹のハチの評価値の平均. $GL(t)$ は $(t+1)$ の時の PL に選ばれる確率であり, 高評価値の巡経路ほど選ばれやすくなっている. ここで, $P_{fg_{best}} < P_{fg}(t)$ の時, $P_{fg_{best}}$ と $PL_g(t)$ を更新.

以下の表は, すべてのハチ M が $(t+1)$ の時, $GL(t)$ か $PL_g(t)$ のどちらを用いるかの決定を行う確率を示す.

表1 Waggle Dance に従う確率

Profitability Scores	P_{follow}
$P_{fg} < 0.95P_{f_{colony}}$	0.80
$0.95P_{f_{colony}} \leq P_{fg} < 0.975P_{f_{colony}}$	0.20
$0.975P_{f_{colony}} \leq P_{fg} < 0.99P_{f_{colony}}$	0.02
$0.99P_{f_{colony}} \leq P_{fg} \leq P_{fg}$	0

[Step. 4] (ローカルサーチ)

$t > t_{local}$ 以降, 以下の処理を実行する. [Step. 3] と同様の処理を M_l についても行う. ローカルサーチの $GL(t)$ を用いて巡経路をカウントする.

もし $GL(t+1) = GL(t)$ の時, $t_R(t+1) = t_R(t) + 1$ する. そして $t_R(t) > t_{limit}$ または一定周期経過した時, ローカルサーチを初期化, $t_R(t) = 0$ とする.

[Step. 5] $t = t+1$ を行う. $t = t_{max}$ に達していなければ, [Step. 2] に戻る. t_{local} はローカルサーチの開始ポイント.

3. シミュレーション

本報告では, PBHCO の性能を att48(都市数 $N = 48$) と kroA100(都市数 $N = 100$) の2種類の TSP を用いて標準 HCO を比較することで評価を行う. 更新数: $t_{max} = 2000$ 回, シミュレーション回数: 10 回とする. ハチの数 M はそれぞれの都市数と等しいものとし, 標準 HCO と HCOR&R のパラメータは以下のように設定する.

$$\lambda = 0.95, \alpha = 1, \beta = 10, \gamma = 15, R = 0.65, t_{limit} = 30$$

t_{limit} はローカルサーチの初期化カウント. 得られた解と最適解を比較するために次のような誤差率を用いる.

$$\text{誤差率} [\%] = \frac{(\text{得られた解}) - (\text{最適解})}{(\text{最適解})} \times 100 \quad (8)$$

この式は巡経路の長さが最適解と比べた場合, どれくらい長いかわを示したものであり, 誤差率が 0 に近いほど最適解に近い. また, HCOR&R が HCO と比べてどれくらい改善されたかを評価するために以下の式を用いる.

$$\text{改善率} [\%] = \frac{(\text{HCO の誤差率}) - (\text{HCOR\&R の誤差率})}{(\text{HCO の最適解})} \times 100 \quad (9)$$

3.1 att48

まず初めに, att48(都市数 $N = 48$) の TSP について得られた解を表 2 に示す.

表 2 att48 における結果

		HCO	HCOR & R
誤差率	平均 [%]	2.43	1.73
	最小値 [%]	1.58	0.08
	標準偏差 [%]	0.62	0.53
改善率 [%]		-	28.81

HCOR&R は標準 HCO より平均値, 最小値において良い解を得ることができた. また, 標準偏差も HCOR&R のほうが良かったことからローカル探索は有効であると考えられる.

3.2 kroA100

次に, kroA100(都市数 $N = 100$) の TSP について得られた解を表 3 に示す.

表 3 kroA100 における結果

		HCO	HCOR & R
誤差率	平均 [%]	11.2	9.27
	最小値 [%]	9.57	6.8
	標準偏差 [%]	1	1.5
改善率 [%]		-	17.23

平均値及び最小値において HCOR&R は HCO より良い結果を得, 標準偏差でも標準 HCO より大きく改善された. ただし, 改善率は 17[%] と 48 都市の 28[%] と減少した. これは 100 都市において 2 つに分割した場合でも, 都市数は 48 都市を上回る数となりローカルサーチにおいても細部まで探索できないといった結果になってると考えられる. この問題を改善するために, 分割数を増やして 1 か所のローカルサーチが探索する都市数を減らし, より細部まで探索できるようにすることが必要であるとされる.

4. ま と め

本報告で, 私たちは役割分担するミツバチコロニー最適化 (Honeybee Colony Optimization with Role and Responsibility: HCOR&R) を提案した. HCOR&R を 2 種類の TSP に適用することで性能の調査を行った. その結果, att48(都市数 $N = 48$) ではローカルサーチにおける改善が大きく見られたが, kroA100(都市数 $N = 100$) では att48 と比較して改善率が減少した. これは都市数に対して, 分割数の不足が原因ではないかと考えられる. 今後の課題として, 共通都市の決定方法の工夫及び複数の共通都市で複数個分割によるローカルサーチなどがある.

文 献

- [1] M. Dorigo and T. Stutzle, "Ant Colony Optimization," Bradford Books, 2004.
- [2] H. Koshmizu, T. Saito, "Parallel Ant Colony Optimizers with Local and Global Ants," Proceedings of International Joint Conference on Neural Networks, 2009.
- [3] J. Kennedy and R. Eberhart, "Particle swarm optimization," Proc. IEEE Int. Conf. on Neural Networks, vol. 4, pp. 1942-1948, 1995.
- [4] D.T. Pham, A. Ghanbarzaden, E. Koc, S. Otri, S. Rahim and M. Zaidi, "The Bees Algorithm - A Novel Tool for Complex Optimization Problems," Intelligent Production Machines and Systems, pp. 454-459, Cardiff University, UK, 2006.
- [5] L. Wong, M.Y.H. Low, C.S. Chong, "Bee Colony Optimization with Local Search for Traveling Salesman Problem," in Proc. of 6th IEEE International Conference on Industrial Informatics (INDIN2008), pp. 1019-1025, Nanyang Technol University, 2008.
- [6] L. Wong, M.Y.H. Low, C.S. Chong, "An Efficient Bee Colony Optimization Algorithm for Traveling Salesman Problem using Frequency-based Pruning," 7th IEEE International Conference on Industrial Informatics (INDIN2009), pp. 775-782, Nanyang Technol University, 2009.
- [7] C.Gruter and W.M. Farina, "The honeybee waggle dance: can we follow the steps?," Trends in Ecology and Evolution vol. 24, pp. 242-247, 2008.