経験的知識に基づく遺伝子操作を導入したGAによる 効率的なモジュール構造型ロボットの迷路巡航学習

学生員 須田 祐* 正員 濱上 知樹*
正員 小坪 成一* 正員 平田 廣則*

An Improved Genetic Algorithm Including Genetic Operator Based on Empirical Knowledge
and Its Application to Navigation of Mobile Robot with Module Architecture

Tasuku Suda*, Student Member, Tomoki Hamagami*, Member, Seiichi Koakutsu*, Member,
Hironori Hirata*, Member

In this paper, we propose a genetic algorithm including genetic operator based on empirical knowledge. We demonstrate the advantages of the proposed method by applying it to a problem of navigation of robot. In the proposed method, when a robot can't complete a task, the weight, which is corresponding to gene, of the activation network which decides the behavior of the robot is revised directly by using the empirical knowledge. Heuristic rules used in the genetic operator based on empirical knowledge are determined to constructs a robot which has better ability than before modified by designer. Computational experiments show that the proposed method raises fitness in earlier generation than the conventional GA.

キーワード：自律移動ロボット, 遺伝的アルゴリズム, ニューラルネットワーク, モジュール構造

Keywords: Mobile Robot, Genetic Algorithms, Neural Network, Module Architecture,

1. ま え が き

従来, ロボットの制御システムの設計方法として設計者がトップダウン的にシステムのすべてを設計する方法が用いられている。しかし近年, システムの肥大化, および複雑化にともない, 設計者がトップダウン的にシステムのすべてを構築することが困難になりつつある。これに対してロボットに学習機構を組み込み, 設計者はある基本的な構造と評価方式, 構造変化のルールだけを与え, 細部についてはロボット自身が環境との相互作用を通して適切な動作を学習するボトムアップ的なシステム設計法が研究されている⁽¹⁾。

このようなシステムの一つとしてニューラルネットワークによりロボットの行動を決定する手法があげられる⁽²⁾。ニューラルネットワークの構造を進化させる方法の一つとして, 遺伝的アルゴリズム (Genetic Algorithms, 以下, GA)⁽³⁾ が用いられる。これにより, システムの構造を環境へ適したものと進化させることができる。しかし, 複雑なタスクが要求された場合, GA による学習には多大な計

算時間が必要となる。そこで, より高速で効率のよい学習法が求められている。

以上のような問題の解決策として, システムをモジュール構造化する手法が提案され, 自律移動ロボットの電源管理問題や荷物運搬問題などに応用されて成果をあげている⁽⁴⁾。この手法では, システムをいくつかの基本的なモジュールに分解し, モジュールを選択することでロボットの行動を決定する。モジュール選択の際に用いる活性ネットワークを GA を用いて進化させることでロボットは学習する。この手法の特徴として, 既知の行動に対しては既存のモジュールをそのまま利用できる, 学習に要する計算時間を短縮できるといった利点がある。しかし, 従来手法の GA による進化だけでは局所解や, それにも満たない状態に長時間とどまる現象がしばしば見られ, 解の探索の効率が悪い⁽⁵⁾⁽⁶⁾。

そこで本論文では, モジュール構造型の特徴を用いた経験的知識に基づく遺伝子操作を導入した GA を提案する⁽⁷⁾。具体的には, 個体の試行の結果に応じて, 設計時, および予備実験時に設計者が得た経験的な知識により, モジュール構造型において, 行動を決定する際に用いる活性ネットワークを, 良好な結果が得られると考えられる方向に修正する。この操作を, ロボットの迷路巡航に応用し, GA の進化過程に加えることにより, 進化が促進され, 解探索の効率化が期待できる。

*千葉大学

〒263-8522 千葉市稲毛区弥生町 1-33

Chiba University.

1-33, Yayoi-cho, Inage-ku, Chiba 263-8522

以降, 2. ではロボットの行動モデルについて述べる。3. では本論文の提案手法である経験的知識に基づく遺伝子操作を導入した GA について述べる。4. では実験の手順を示し, 5. では実験結果と, それに対する考察を述べ, 最後に 6. で本論文を総括し, 今後の課題を述べる。

2. ロボットの進化的行動獲得

〈2・1〉 自律移動ロボット ケペラ (Khepera) ロボットは, プログラミングによる制御が可能な小型ロボットである。図 1 に示すように周囲に近接センサ, 光センサとして使用可能な 8 個のセンサを持つ。移動のために左右独立に回転可能な 2 個のモータを持ち, それぞれ前方または後方へ回転方向を指定できる。本論文では, 本ロボットをシミュレートした計算機実験システム⁽⁸⁾を用いる。

図 1 ケペラロボット

Fig. 1. The Khepera robot.

〈2・2〉 ロボットの迷路巡航 本論文のタスクであるロボットの迷路巡航とは, 迷路内に配置された餌をロボットが必要に応じて拾い集め, ゴールを目指す行動である。また, より短いステップでゴールに到達することを目的とする。

環境内には餌としてランプを配置する。ロボットは光センサによりこれを感知し, 餌回収行動を行う。ロボットがランプの周囲一定距離内に接近した場合, ランプを消灯し, 餌が回収されたときみなす。またゴール地点にもランプを配置し, 一定距離内に接近した場合は試行が達成されたとする。

餌が回収された場合, ロボットには一定量のバッテリーが与えられる。バッテリーは時間の経過とともに消費される。そして, バッテリーが 0 になった時点で, ロボットは行動を停止する。また, ロボットが障害物に衝突した場合も, 同様に行動を停止する。したがってロボットは, 障害物を回避しながら, 必要に応じて餌を回収し, ゴールを目指さなくてはならない。

ロボットはバッテリーが 0 でない限り最大ステップ数に達するまで環境内を自由に動き回ることができる。そして, 試行が終了した際に環境に対する適応度を与えられる。また, ロボットは自身の現在位置を把握できず, 明示的に環境内の地図を記憶するメモリを持たないものとする。

〈2・3〉 モジュール構造型自律移動ロボット あるタスクを達成するロボットに着目すると, それはいくつかの機能に分解できる。その一つ一つの機能ごとに, 適切なモ

図 2 モジュール構造型自律移動ロボットの構成

Fig. 2. Composition of mobile robot with module architecture.

ジュールを作る。モジュールを選択することで与えられたタスクを達成するための行動を自律的に獲得するロボットを, モジュール構造型自律移動ロボット⁽⁴⁾という。

本論文で用いるモジュール構造型自律移動ロボットの構成を図 2 に示す。

モジュール構造型自律移動ロボットは, 以下のように構成される。センサからの入力 (Sensory Inputs) は, 活性ネットワーク (Activation Network), 行動発生器 (Behavior Generator) のそれぞれに入力される。活性ネットワークは, ニューラルネットワークにより実現する。センサ値を入力とし, 各モジュールの活性度を出力とする。各時間ステップごとに, 最も高い活性度を持つモジュールがモータにアクセスし, ロボットを制御する。行動発生器内の各モジュールはルールベース, ニューラルネットワーク, クラシファイアシステムなど, センサ入力に対するモータ制御の行動決定に適する構成を用いる。本ロボットの行動発生器は, 直進 (Go Forward), 障害物回避 (Avoid), 餌回収 (Go for Food) の 3 種のモジュールから構成される。直進モジュールでは, 行動発生器は常に直進するようにモータを制御する。障害物回避モジュールや餌回収モジュールよりも高速な移動が可能である。障害物回避モジュールでは, 行動発生器は 8 個の近接センサの入力により, 常に障害物から遠ざかる出力を出すニューラルネットワークを用いて, モータを制御する。餌回収モジュールでは, 行動発生器は 8 個の光センサの入力により, あらかじめ決められたルールに従い, 4 行動 (直進, 右回転, 左回転, 後退) から一つを選択し, モータを制御する。

3. 経験的知識に基づく遺伝子操作を導入した GA

〈3・1〉 GA による進化 モジュール構造型自律移動ロボットの学習における課題は, 状況に応じて適切なモジュールを選択することにある。モジュールの選択は活性ネットワークにより行う。

活性ネットワークの構造を図 3 に示す。活性ネットワー

図3 活性ネットワーク

Fig. 3. Activation network.

クの出力は、それぞれ各モジュールの活性度を表し、活性度の最も大きいモジュールが選択される。各素子には線形素子を用いる。この活性ネットワークの結合の重みを GA を用いて進化させることにより、適切なモジュールを選択できるようにする。

GA を用いる際の遺伝子コード化は、活性ネットワークの重みを実数値として並べた一次元配列を染色体とする。本論文で用いる活性ネットワークでは、Bias と各出力間の重みの値を固定し、各センサ入力と出力間を可変とするので、染色体長は各センサ入力と各出力間の接続の数である 48 となる。遺伝的操作には、一点交叉と突然変異を用いる。世代交代は、集団 N_a 個体の中から、適応度の高い N_e 個体をエリートとしてそのまま次世代に残し、 N_e 個体をルーレット選択により、選択した親個体に交叉、突然変異を施すことにより生成し、 N_n 個体は新たにランダムに生成する。交叉確率は P_c 、突然変異率は P_m とする。

〈3・2〉 経験的知識に基づく遺伝子操作 従来手法の GA による進化だけでは局所解や、それにも満たない状態に長時間とどまる現象がしばしば見られ、解の探索の効率が悪い。本論文では、これを解決するために、経験的知識を用いて、遺伝子を直接操作する方法を導入する。

ここで、経験的知識とは、タスクが失敗したときの状態をもとに、タスクが完了しやすくなるよう行動を誘導する調整手段をさす。一般に、入力に基づいて行動が決定する多層のネットワークでは、望ましい行動を誘導する調整を、効果的に行うことは困難である。一方、モジュール構造型ロボットにおいては、とりうる行動の傾向が、モジュール選択を行う活性ネットワークの重みにより、直接的に表現することができる。この特徴を用いることで、設計者は設計時、および予備実験から経験的に得られた知識に基づき、ロボットの行動をより望ましい方向へ誘導することが可能となる。具体的には、行動モジュールを選択する活性ネットワークの重みを、後述する条件に応じて強化または抑制するための遺伝子操作を行う。この操作を、GA の進化過程に加えることにより、進化が促進され、解探索の効

率が期待できる。

重みの強化、抑制は以下の式により行う。式中の w_a は修正後の重み、 w_b は修正前の重み、 α は正の修正係数、 I は入力層のニューロンへの入力とする。

$$w_a = \begin{cases} w_b + \alpha I & (\text{強化則}) \\ w_b - \alpha I & (\text{抑制則}) \end{cases} \dots\dots\dots (1)$$

試行が中断される各条件に対応する活性ネットワークの重みの修正方法を以下に示す。

● 効率的巡航を促進する遺伝子操作

ロボットが最大ステップに達した場合、試行の途中に無駄な寄り道があったと考え、強化則に従いすべての入力と直進モジュール間の重みを修正し、すべての入力と障害物回避、餌回収モジュール間の重みを抑制則に従い修正する。

● バッテリー切れを防ぐ遺伝子操作

ロボットのバッテリーが 0 になった場合、試行の途中に必要な餌を回収することができなかったと考え、強化則に従いすべての入力と餌回収モジュール間の重みを修正し、すべての入力と直進、障害物回避モジュール間の重みを抑制則に従い修正する。

● 衝突を回避する遺伝子操作

ロボットが障害物に衝突した場合、衝突の直前に適切なモジュール選択がなされなかったと考え、強化則に従いすべての入力と障害物回避モジュール間の重みを修正し、すべての入力と衝突する直前に選択されたモジュール間の重みを抑制則に従い修正する。

4. 実験環境

〈4・1〉 環境 ロボットの迷路巡航は図 4 に示す環境で実験する。環境中の $\times$ はランプ (餌)、 $\bigcirc$ はゴールを表す。ロボットは与えられた規定ステップ内で障害物を回避しながら、餌を回収し、ゴールを目指す。ロボットのセンサはノイズの影響を受け、またロボットの光センサは壁ごしのランプの光にも反応し、障害物センサはランプも壁と同様に障害物として反応する。よって、この環境においてロボットはスタート地点近くの最初の餌を回収した後、壁ごしのランプに反応しその方向に進み、壁に衝突するという現象がおきやすい。このため、実験環境は従来の GA だけでは困難な環境である。

〈4・2〉 実験手順 実験の手順を以下に示す。

手順 1 初期集団を N_a 個体生成する。各個体は初期バッテリー量 B_f と最大ステップ数 $S_{\max}$ を持つ。以上を世代 1 とする。

手順 2 センサ入力に対して行動発生器が 1 回出力した状態を 1 ステップとする。1 ステップ毎にバッテリー量を 1 減少させる。

手順 3 ロボットは餌の周囲 $r[\text{mm}]$ 以内に接近することで餌を回収し、バッテリーを一定量 B_c だけ補給する。

図4 実験環境

Fig. 4. Maze environment.

手順4 各ステップごとに手順2, 手順3を繰り返し, ゴールに到達した時点でその個体の試行を終了する。また, 最大ステップ数に達する, バッテリーが0になる, 障害物に衝突するのいずれかの場合にはゴールに到達していなくても試行を終了する。〈3.2〉で述べた条件を満たした個体に遺伝子操作を行う。

手順5 試行が終了した時点で式(2)により適応度 f を計算する。

$$f = \begin{cases} L_a + \beta(S_{\max} - S) \\ L_g + \gamma \left(\sum_{i=1}^{L_g} (S_{\max} - S_{gi}) + S \right) \end{cases} \quad (2)$$

式(2)の上段はゴールに到達した場合の適応度関数である。ここで L_a は環境内の餌の数, S は試行終了時の経過ステップ数である。よって, ゴール到達が早いほど適応度は増加する。式(2)の下段は試行が中断された場合の適応度関数である。ここで L_g は回収した餌の数, S_{gi} は i 番目の餌を回収した時点での経過ステップ数である。よって, より多くの餌を早く回収するほど適応度は増加する。 β, γ はともに定数である。

手順6 試行が終了, もしくは中断された個体は初期位置に戻してさらに2回手順2~5を繰り返す。試行が中断された個体の試行を繰り返す場合は, 重みが修正された活性ネットワークを用いる。3回の試行の適応度の平均をその個体の当該世代の適応度とする。個体の適応度を算出する際に平均をとる理由は3回の試行すべてにおいてタスクを達成した個体, 3回の試行すべてにおいてタスクを達成できなかった個体, および1回, 又は2回達成した個体の差別化をはかるためである。

手順7 すべての個体について手順2~6を繰り返す。

手順8 計算された適応度に従い〈3.1〉で述べた遺伝的操

作を施し, 新集団を生成する。以上により世代を1つ進める。

手順9 終了条件を満たすまで手順2~8を繰り返す。

5. 計算機実験

〈5.1〉実験条件 本実験で用いる各種パラメータの値を表1に示す。シミュレーションは200世代まで行う。遺伝子操作の修正係数 α は, 0.1, 0.3, 0.8の3通りの場合で実験を行い, 経験的知識に基づく遺伝子操作を行わない場合 ($\alpha = 0$) と比較する。

〈5.2〉実験結果 図5~7に結果を示す。図5は適応度の値がほぼ最高の値である約21の場合の獲得行動の一例である。ロボットの色が灰色なら直進モジュール, 黒なら障害物回避モジュール, 白なら餌回収モジュールが選択されていることを表す。図6のグラフの x 軸は世代数を表し, y 軸は各世代の中で最も適応度の高い個体 (エリート) の適応度の20回の実験における平均値を表す。図7のグラフは20回の実験においてゴールに到達できる個体が得られている割合を表す。

〈5.3〉考察 図6, 図7から提案手法の方が従来手法に比べて早い時期に適応度が上昇し, 適切な行動を獲得することがわかる。修正係数 α が0.1と0.3では早い世代で環境に適応し, 適応度が急激に上昇する。これは経験的知識に基づく遺伝子操作により個体の遺伝子の近傍を探

表1 実験におけるパラメータ値

Table 1. Value of parameters.

name	value	name	value
N_a	30	$S_{\max}$	3500
N_e	4	B_f	500
N_c	16	B_c	750
N_n	10	L_a	4
P_c	1.00	r	5
P_m	0.02	β	0.01
		γ	0.0001

図5 獲得行動例

Fig. 5. An example of behavior.

図6 各世代におけるエリートの適応度の平均値
Fig. 6. Elite fitness of population.

図7 各修正係数の各世代数におけるタスク達成率
Fig. 7. Probability of successful at each generation.

索し、より高い適応度を得ることができるようになった個体が誕生し GA により選択されているためといえる。経験的知識に基づく遺伝子操作は個体が改悪される場合もあり得るが、本手法では GA と組合せることにより改悪された個体は淘汰され、改善された個体が残るため効率の良い進化をすることができる。しかし、修正係数 α が 0.8 になると適応度の上昇は GA のみの場合と同程度にまで下がる。これは遺伝子操作の値が大きくなりすぎ、個体の遺伝子が GA により与えられた 1 回目の試行と大きく異なる値になる。そして、解空間上での距離が大きく離れた個体を同一個体として GA で扱うため、進化を妨げているためと考えられる。しかし、修正係数が大きすぎる場合でも遺伝子操作により高い適応度を得た場合はその個体を選択される。このため通常の GA より高いタスク達成率を最終的に得たといえる。適切な修正係数の大きさは解空間の大きさ、パラメータの変動に対する敏感さなど問題に依存するため一意に決めることは困難であるが調整は容易である。

また、提案手法では試行が中断された場合を経験的知識に基づく遺伝子操作の対象としている。このため、無駄な行動が多く適応度があまり高くない個体の改善は GA のみによる進化に頼っている。

6. む す び

本論文では経験的知識に基づく遺伝子操作を導入した GA により、タスク達成に要する時間の短縮をはかった。計算機実験の結果、提案手法により早い世代で行動を獲得し、高いタスク達成率を得ることが示された。以上より、提案手法の有効性が確認された。修正係数の値が大きすぎる場合、逆に GA による適切な活性ネットワークの探索の妨げになることもあり得る。しかしパラメータ調整は容易である。

今後の課題として、異なるモジュールを用いたロボットや、より複雑なタスクに対する提案手法の応用、実機での実験などがあげられる。

(平成 13 年 12 月 4 日受付, 同 14 年 8 月 9 日再受付)

文 献

- (1) 星野 力: 人工生命の夢と悩み, 裳華房 (1994)
- (2) 馬場則夫・小島史男・小澤誠一: ニューラルネットワークの基礎と応用, 共立出版 (1994)
- (3) 北野宏明: 遺伝的アルゴリズム, 産業図書 (1993)
- (4) J. Urzelai, D. Floreano, M. Dorigo, and M. Colombetti: "Incremental Robot Shaping," *Proc. Genetic Programming 1998*, pp.195-203 (1998)
- (5) Y. Wakahara, S. Koakutsu, and H. Hirata: "Evolution of Hunting Behavior by Autonomous Mobile Robot with Module Architecture" *Proceedings of the Electronics, Information and Systems Conference Electronics, Information and Systems Society, I.E.E. of Japan Vol.1*, pp.745-748 (1999) (in Japanese)
若原頼基・小坪成一・平田廣則: 「モジュール構造型自律移動ロボットによる追跡行動の進化的獲得」, 平成 11 年 電気学会電子・情報・システム部門大会講演論文集, pp.745-748 (1999)
- (6) S. Ishibashi, S. Koakutsu, and H. Hirata: "Evolution of Collecting Behavior by Autonomous Mobile Robot with Module Architecture" *Proceedings of the Electronics, Information and Systems Conference Electronics, Information and Systems Society, I.E.E. of Japan Vol.1*, pp.593-596 (2000) (in Japanese)
石橋真哉・小坪成一・平田廣則: 「モジュール構造型自律移動ロボットによる巡回行動の進化的獲得」, 平成 12 年 電気学会電子・情報・システム部門大会講演論文集, pp.593-596 (2000)
- (7) T. Suda, T. Hamagami, S. Koakutsu, and H. Hirata: "An Improved Genetic Algorithm Based on Heuristic Approach and Its Application to Navigation of Mobile Robot with Module Architecture" *Proceedings of the Electronics, Information and Systems Conference Electronics, Information and Systems Society, I.E.E. of Japan Vol.1*, pp.461-464 (2001) (in Japanese)
須田 祐・濱上知樹・小坪成一・平田廣則: 「発見的手法を導入した GA によるモジュール構造型ロボットの迷路巡航」, 平成 13 年 電気学会電子・情報・システム部門大会講演論文集 [I], pp.461-464 (2001)
- (8) O. Michel: "Khepera Simulator Package version 2.0: Free-ware mobile robot simulator written at the University of Nice Sophia-Antipolis by Oliver Michel," Downloadable from the World Wide Web at <http://www13s.unice.fr/~om/khep-sim.ht> ml. (1996)

須田 祐 (学生員) 1978年12月18日生。2001年、千葉大学工学部電気電子工学科卒業。同年、千葉大学大学院自然科学研究科電子機械科学専攻博士前期(修士)課程に入学、現在に至る。進化型計算、自律移動ロボットの研究に従事。

濱上 知樹 (正員) 1966年3月7日生。88年千葉大学工学部電気工学科卒業。セコム(株)勤務を経て、99年在職のまま千葉大学大学院自然科学研究科生産科学専攻後期課程修了。2001年同助手となり現在に至る。大規模システムの数値、マルチエージェント、機械学習、創発システムの応用研究に従事。博士(工学)。IEEE、電子情報通信学会会員。

小 坪 成 一 (正員) 1964年7月7日生。92年千葉大学大学院自然科学研究科生産科学専攻博士課程修了。同年千葉大学工学部助手、97年同助教授、同年同大学院自然科学研究科助教授となり現在に至る。94~95年カリフォルニア大学サンタクルズ校客員研究員。VLSIレイアウト設計、確率的最適化手法、ニューラルネットワークの研究に従事。博士(工学)。IEEE、INNS、電子情報通信学会、計測自動制御学会会員。

平 田 廣 則 (正員) 1948年6月2日生。76年東京工業大学大学院電気工学専攻博士課程修了。同年千葉大学工学部助手、81年同助教授、94年同教授、97年同大学院自然科学研究科教授となり現在に至る。大規模システムのモデリング、解析と設計、特に生態システム、VLSIレイアウト、並びに分散型コンピュータの基礎的理論に興味を持つ。工学博士。2001年電気学会業績賞受賞。IEEE、ISEM、INNS、電子情報通信学会、情報処理学会、計測自動制御学会、システム制御情報学会、人工知能学会会員。