

進化計算群を用いた仮想流体環境における人工生物の行動獲得とその比較

北海道大学 ○中村啓太, 北見工業大学 鈴木育男, 北海道大学 山本雅人, 北海道大学 古川正志

人工ニューラルネットワーク (ANN) の最適化には多くの進化計算が存在する. 本研究では, ANN を人工生物の制御に利用し, 流体の影響を考慮した人工生物の行動獲得実験を行う. 各進化計算を ANN の結合重みの最適化に適用し, 各方法で獲得した行動を比較し, どのような特徴があるかを調査する.

1. はじめに

近年, 進化計算を利用した人工ニューラルネットワーク (ANN) の最適化方法が多く存在する. これまで著者らは, 人工生物の行動獲得実験を行うことを目的とし, ANN を人工生物の制御に採用し, 実数値型遺伝的アルゴリズム (RCGA) を ANN の結合重みの最適化に適用することで, コンピュータ上で人工生物の行動獲得を行ってきた¹⁾.

そこで本研究では, 各進化計算にどのような特徴があるかを調査することを目的とし, まず, 流体の影響を考慮した仮想環境を構築し, その環境下で人工生物の光源追跡獲得実験を行う. 人工生物の制御に ANN を採用し, 各進化計算を ANN の結合重みの最適化に適用する. 各方法で獲得した行動を比較し, どのような特徴があるかを明らかにする.

2. 人工生物モデル

2.1 遊泳人工生物モデル

実験で用いる人工生物モデルは, 魚を模倣しており, 同じ剛体を繋げて作製する (図 1). この人工生物は, 視界内に存在する光源を検知するセンサ (図 2) と 1 自由度のアクチュエータ $[-45^\circ, 45^\circ]$ (図 3) を所持している. また, この人工生物の密度は, 水の密度と等しくなるように設定した.

2.2 人工生物の制御方法

作製した人工生物の状態に応じて, 自律的に行動するため, 脳のメカニズムをモデル化した ANN を適用し, アクチュエータの出力制御を行う. 本実験では 3 層 ANN を採用した.

ANN の入力には, アクチュエータ i における剛体間の角度 (θ_i), 角速度 (ω_i), 人工生物の進行方向と光源との角度 ($\cos \theta$, $\sin \theta$) とし, 人工生物が光源を認識しない場合, どちらの入力を 1.0 とした. また, ANN の出力をアクチュエータ i における剛体間の角度を A_i になるように設定した. 中間層のニューロン数は, 入力層のニューロン数と同じとし, ANN の結合重みをランダムな値で初期化する. 評価関数に応じて, この結合重みを最適化し, 目標行動獲得を可能にする.

3. 数値計算実験

本実験では, ANN の結合重みを最適化する進化計算にどのような特徴があるかを調査するために, 文献¹⁾に基づいて, 流体の密度を $998.20[\text{kg}/\text{m}^3]$, 重力加速度を $9.80[\text{m}/\text{s}^2]$ と設定した仮想流体環境を構築し, その環境下で人工生物が光源に向かう行動の獲得実験を行った. 今回, 実数値型遺伝的アルゴリズム (RCGA)²⁾, 粒子群最適化 (PSO)³⁾, 進化戦略 ($(\mu + \lambda)$ -ES, (μ, λ) -ES)⁴⁾ の 4 種類の進化計算を ANN の最適化に適用した.

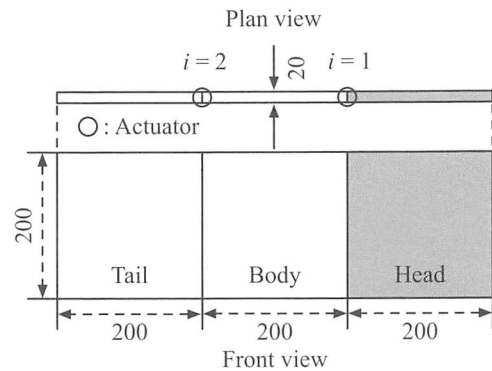


Fig.1 Virtual animated model




Fig.2 Sensor (Plan view)

Fig.3 Actuator (Plan view)

3.1 実験条件

光源を人工生物の正面, 左後方, 右後方の 3 箇所に設置し (図 4), 人工生物が制限時間内に遊泳で近づく実験を行った. 人工生物の初速度は $0.0[\text{m}/\text{s}]$ としている. 人工生物を制御する ANN の結合重みを遺伝子として, 各進化計算を適用して最適化を行う. 今回, 交叉方法はブレンド交叉²⁾, 突然変異方法は各結合重みに対して, 標準正規乱数を加える方法を採用した. そして, 3 つの光源に対して, 1 ステップを $1/60[\text{s}]$ とし, 600 ステップの間, 人工生物のシミュレートを行い, 200 世代まで更新する. 表 1 に各方法の条件を示す. 各方法の評価値 E_j ($j = 1, 2, 3$) は, 人工生物ができる限り速く, 真っ直ぐに光源に向かうように式 (1) で設定する.

$$E_j = \sum_{t=0}^T (|I_j - \mathbf{P}(t)| - \alpha \cos \theta(t)) \quad (1)$$

評価値 F は光源 j に対して, 評価 E_j を求め, 評価 E_j の中で一番悪い値を, 個体の評価 F を式 (2) のように設定する.

$$F = \max(E_1, E_2, E_3) \quad (2)$$




Fig.4 Initialize state of an experiment (Plan view)

Table1 Experimental conditions for ANN control

| ANN | The range of a joint angle | $[-45^\circ, 45^\circ]$ |
|-----------------------|------------------------------|-------------------------|
| RCGA | Population | 50 |
| | Mutation Probability | 0.8 |
| | Crossover Probability | 0.2 |
| | Elite Individual | 5 |
| PSO | Particle | 50 |
| | w (Inertia Coefficient) | 0.8 |
| | C_1 (Global best solution) | 2.0 |
| | C_2 (Local best solution) | 2.0 |
| $(\mu + \lambda)$ -ES | μ Population | 20 |
| | λ Population | 30 |
| | Mutation Probability | 0.8 |
| | Crossover Probability | 0.2 |
| (μ, λ) -ES | μ Population | 20 |
| | λ Population | 50 |
| | Mutation Probability | 0.8 |
| | Crossover Probability | 0.2 |

ここで、 T は総シミュレーションステップ数、 L_j は光源 j の座標、 $\mathbf{P}(t)$ はステップ t での人工生物の座標、 $\theta(t)$ はステップ t でのセンサ角度、 α は比例定数 (1.5) とした。この評価値 F を良くすることで、人工生物を各光源に到達させる。各手法に対してこの最適化を 10 試行実施する。

3.2 実験結果

各最適化手法での世代数と評価値との関係 (10 試行) を図 5 に示す。この結果から、PSO, ES の最良評価値は RCGA に比べて良い値を示すことがわかる。しかしながら、PSO, (μ, λ) -ES の最悪評価値は RCGA の評価値よりも悪いため、複数試行を実験を行う必要がある。

次に、各最適化手法で獲得した最良個体の軌跡をプロットしたものを図 6 に示す。この結果から、どの最適化手法でも、設置した 3 つの光源に向かうことができるが、RCGA で獲得した個体のみが制限時間内に光源に到着できないことがわかる。

4. おわりに

本研究では、進化計算を利用した ANN の最適化手法の特徴を調べるために、流体の影響を考慮した仮想環境を構築し、その環境下で、関節数が 2 つの人工生物モデルが複数の光源に向

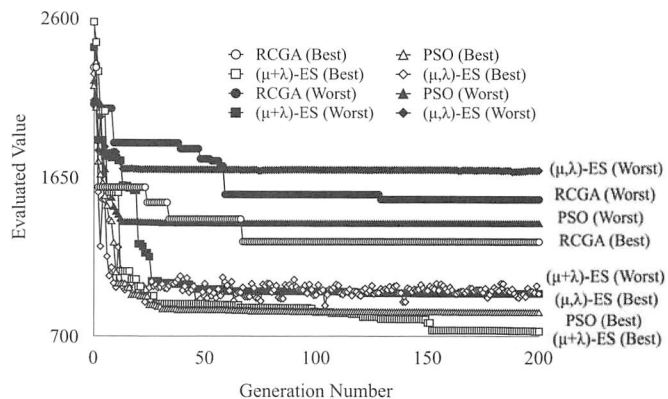


Fig.5 Relation between generation number and fitness value

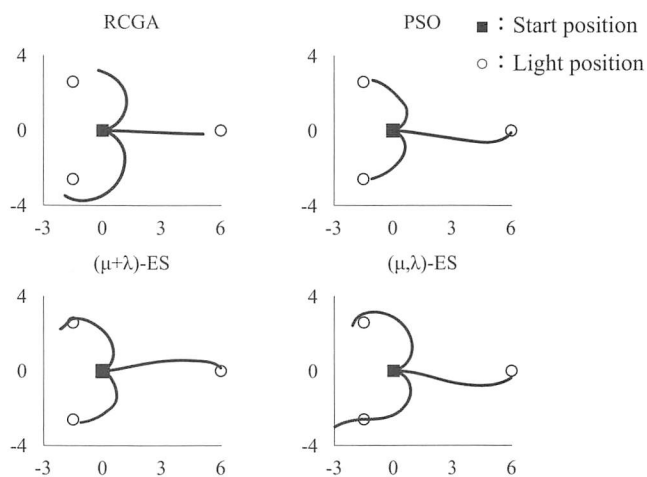


Fig.6 Trajectory of best individual for each optimizing method (Plan view)

かう行動を獲得する実験を行った。実験結果から、RCGA よりも PSO, ES を用いた方がより良い行動を獲得することがわかった。今後の課題として、関節数の多い人工生物モデルの行動獲得実験を行い、より規模の大きい ANN の最適化を行い、どの最適化手法が良いかを調査することが挙げられる。

参考文献

- 1) K. Nakamura, I. Suzuki, M. Yamamoto, and M. Furukawa: Acquisition of Swimming Behavior on Artificial Creature in Virtual Water Environment, In Advances in Artificial Life, ECAL 2009:10th European Conference, Revised Selected Papers, 1, 5777, (2011) 99
- 2) L. J. Eshelman and J. D. Schaefer: Real-Coded Genetic Algorithms and Interval-Schemata, Foundations of Genetic Algorithms, 2, (1993) 187
- 3) J. Kennedy and R. Eberhart: Particle swarm optimization, Neural Networks, 1995. Proceedings, IEEE International Conference on, (1995) 1942
- 4) T. Back, F. Hoffmeister and H. P. Schwefel: A survey of evolution strategies, Proceedings of the Fourth International Conference on Genetic Algorithms, (1991)