

複数の木構造を持つ遺伝的プログラミングの改良 Improvement of Genetic Programming with multiple trees

伊藤 崇
Takashi Ito

高橋 健一
Kenichi Takahashi

稲葉 通将
Michimasa Inaba

広島市立大学大学院情報科学研究科知能工学専攻

Email: ito@cm.info.hiroshima-cu.ac.jp

Email: takahasi@hiroshima-cu.ac.jp

Email: inaba@hiroshima-cu.ac.jp

Abstract— This paper proposes Genetic Programming(GP) with control nodes using the conditional probability and the island model. In our methods, each individual has a chromosome representing agent behavior as several trees. In GP using the conditional probability, individuals with high fitness values are used to produce conditional probability tables to generate individuals in the next generation. In GP using the island model, the population is divided into two islands of individuals: one island keeps diversity of individuals and the other puts emphasis on the accuracy of the solution. The methods are applied to a garbage collection problem and Santa Fe Trail problem. Our methods are compared with traditional GP, GP with control nodes, and Genetic Network Programming(GNP) with control nodes. Experimental results show that our methods are efficient in the garbage collection problem.

I. はじめに

人間の知能の模倣を目指す人工知能分野において、目的を達成するためにエージェントの判断と行動の規則を自動生成する手法の研究が行われてきた[1]. その学習手法の一つである遺伝的ネットワークプログラミング (GNP) は、遺伝的プログラミング (GP) よりも効率的に最適解を発見できることが知られている. また, GNP における解の探索効率を向上させる手法として, 調整ノード付 GNP (GNP_{CN}) が提案されている. しかし GNP_{CN} は, 得られる規則の可読性が低く, ネットワークの構造を十分に利用しないという欠点がある. この問題を解決する手法の一つに, 複数の木を一個体とする調整ノード付き GP (GP_{CN}) がある. しかし GP_{CN} は, GNP_{CN} よりも探索効率が悪いことが先行研究によって明らかとなっている.

本研究では, GP_{CN} の探索効率を向上させる手法として, 条件付確率を用いた GP_{CN} (GP_{CN_CP}) [2]と島モデル型 GP_{CN} (GP_{CN_IL}) を提案する. GP_{CN_CP} では, 条件付確率を用いて生成した個体と遺伝操作によって生成した個体の双方を次世

代の個体集団とする. これにより, 個体集団の多様性を維持し, かつ優良個体の構造を次世代へ高い確率で継承することができる. また, GP_{CN} は局所解に陥ってしまう問題があるため, 島モデル型 GP_{CN} (GP_{CN_IL})を導入する. GP_{CN_IL} では母集団を 2 つの島に分解して探索を行う. 成績重視の島では, 適合度を上げることに重点を置き, 個性尊重の島では多様性の維持に重点を置き探索を行う. それぞれの島において, 多様性の維持と解の精度の向上という異なる 2 つに重点を置くことができるため, 局所解に陥りにくくなると期待できる.

本研究では, 従来手法である GNP_{CN} , GP_{CN} と提案手法である GP_{CN_CP} , GP_{CN_IL} を, ごみ拾い問題と Santa Fe Trail 問題に適用し, 性能を比較する.

II. 調整ノード付き GNP (GNP_{CN})

GNP の解の探索効率を向上させる手法として, 調整ノード付き GNP (GNP_{CN}) が提案されている. GNP_{CN} の個体は, GNP で使われていた判定ノードと処理ノードに, 調整ノードを加えた 3 つのノードがネットワーク上に接続された構造となっている. GNP_{CN} の個体例を図 1 に示す.

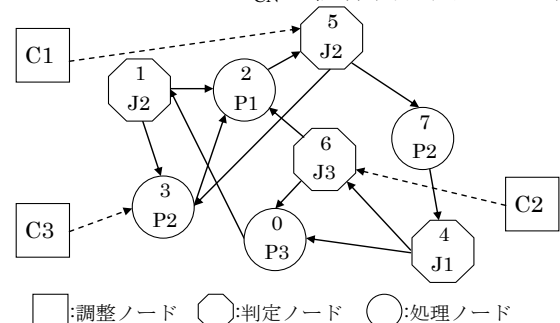


図 1 調整ノード付き GNP の個体例

調整ノードは, 開始ノードに類似したノードであり, エージェントが参照するノードを制御する. また, 調整ノードには順番を表す番号が割り振られており, 小さい番号の調整ノードから参照し, 一定数の処理ノードを参照すると次の調整ノードに遷移する. ただし, 最も大きい番

号の調整ノードが参照された場合、次に参照されるのは最も小さい番号の調整ノードとする。 GNP_{CN} の遺伝操作は、交叉とノード接続の変更のみである。また、ノード接続の変更では、調整ノードの接続先は遺伝操作によって変更されない。

III. 調整ノード付き GP (GP_{CN})

A. 調整ノード付き GP (GP_{CN})

GNP_{CN} と同じ機能を GP において実現しようとするものとして調整ノード付き GP (GP_{CN}) がある。図 2 に GP_{CN} の個体例を示す。 GP_{CN} の個体は、それぞれが規則に対応する複数の木から構成されている。各木は、調整ノードを根ノードとし、参照される木の順番は調整ノード番号の順とする。一個体の木の数 M (つまり調整ノードの数) は、あらかじめ定義されているとする。自律エージェントの行動学習では、環境から知覚情報を受け取り、調整ノード番号の小さい木から順番に参照し行動を決定する。非終端ノードには知覚情報に関する分岐が、終端ノードにはエージェントが実行できる行動が記されている。ある木を用いてエージェントがくり返し実行する行動回数が一定数 P を超えたとき、参照する木を次の調整ノードを持つ木に変更する。最も大きい調整ノード番号の木が参照された場合、次に参照される木は最も小さい調整ノード番号の木とする。 GP_{CN} の個体は複数の木を持っているが、適合度の計算は個体に対して行い、個々の木については行わない。また、 GP_{CN} における遺伝操作は、従来の GP と同様に交叉、突然変異、逆位の 3 種類である。ただし、1 個体に複数の木を持っているため、遺伝操作ごとにそれぞれの個体の中からランダムに 1 つの木を選択し、遺伝操作を行う。

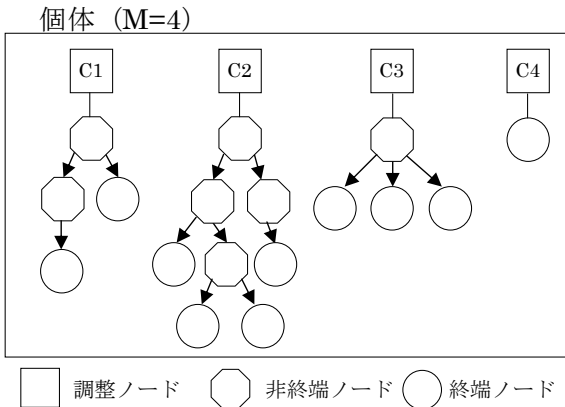


図 2 調整ノード付き GP の個体例

B. 条件付確率を用いた GP_{CN} ($GP_{CN,CP}$)

GP_{CN} では、探索効率が十分でないという問題があった。そこで、条件付き確率を用いた GP_{CN} ($GP_{CN,CP}$) を提案する。開始から、選択までは GP_{CN} と同じ流れである。 GP_{CN} との主な違いは、次世代の個体生成方法にある。 $GP_{CN,CP}$ では、選択後の適合度判定により優良と判定された個体を用いて条件付確率表を作成し、その条件付確率により次世代個体の一部を生成する。このため、優良個体内のノードの親子関係を保持した個体が、高い確率で次世代の個体に出現すると考えられる。

C. 島モデル型 GP_{CN} ($GP_{CN,IL}$)

従来手法である GP_{CN} では、ある一定の適合度まで進化すると局所解に陥ってしまう問題があった。それを改善する手法として島モデル型 GP_{CN} ($GP_{CN,IL}$) を提案する。 $GP_{CN,IL}$ では、多様性を維持しながら適合度を上げることを目的とする。島モデルとは、遺伝的アルゴリズムの拡張手法として提案された並列分散処理手法である。本研究の $GP_{CN,IL}$ は、母集団を成績重視の島と個性尊重の島の 2 つサブ集団に分割し探索を行う。まず、初期集団を生成する。次に個体集団の評価をして、島モデルの特徴の 1 つである移住を行う。その後、終了条件を満たしていなければ、選択、次世代個体の生成を行う。成績重視の島では、エリート保存と交叉のみで次世代個体を生成し、個性尊重の島では、ランダム個体との交換と遺伝操作によって次世代個体を生成する。ランダム個体との交換とは、ランダムで生成した個体と集団内のある個体とを入れ替える操作である。

D. 最適な P 獲得手法

前述の GP_{CN} 、 $GP_{CN,CP}$ 、 $GP_{CN,IL}$ に対して、進化の過程で最適な P の値を獲得する手法を取り入れた $GP_{CN}(e)$ 、 $GP_{CN,CP}(e)$ および $GP_{CN,IL}(e)$ を提案する。シミュレーションの最大ステップ数を $TotalSteps$ としたとき、 P は式(1)により求められる範囲でランダムに求めることとする。

$$P = [1, TotalSteps/C] \quad (1)$$

IV. 実験

A. ゴミ拾い問題

ゴミ拾い問題では、エージェントがフィールド内のすべてのごみを拾い、ごみ収取所に集めることを目的とする。フィールドは、縦 $11 \times$ 横 11 の二次元格子平面で構成され、一番外側のマスは壁とする。フィールド上には、エージェン

トが1体、ごみが10個、ごみ収集所が1箇所設置されている。エージェントは、1ステップで前方に1マス動くか、左右のどちらかに90度回転することができる。また、ごみのあるマスに到達するとごみを回収することができ、ごみ収集所のマスに到達するとごみを廃棄できる。エージェントのごみを運べる最大数は2個とする。10種類の環境を用意し、それぞれ250ステップ内に廃棄できたごみの総数を適合度とする。環境の種類を n 、その環境で捨てられたごみの数を N_n とすると適合度は(2)式により求めることができる。

$$\text{Fitness} = \sum_{n=1}^{10} N_n \quad (2)$$

ゴミ拾い問題における判定ノードと処理ノードの機能を表1に示す。種別は、0が非終端ノード(判定ノード)、1が終端ノード(処理ノード)を示す。また、実験に使用した各手法のパラメータを表2、表3、表4に示す。

表1 非終端ノードと終端ノードの機能

種別	機能(エッジ数)
0	ごみ収集所までの距離(3)
0	エージェントの保持しているごみの数(3)
0	エージェントから見たごみ収集所の方向(8)
0	エージェントから見た最も近いごみの方向(9)
0	エージェントから見た2番目に近いごみの方向(9)
1	前方へ1セル進む(1)
1	右へ90度回転(1)
1	左へ90度回転(1)
1	動かない(1)

表2 GP_{CN} , GP_{CN_CP} のパラメータ

最大世代数	1000
個体数	300
トーナメントサイズ	2
エリート保存数	1
突然変異率	0.05
突然変異木率	0.1
交叉率	0.8
逆位率	0.2
木の最大の深さ	6
Pの値の変更率	0.05
条件付き確率による生成個体数	75

表3 GNP_{CN} のパラメータ

最大世代数	1000
個体数	300
ノード数	18
ノード交叉率	0.1
ノード接続変更率	0.01
調整ノード数	10

表4 GP_{CN_IL} のパラメータ

	成績重視	個性尊重
最大世代数	1000	
個体数	150	
トーナメントサイズ	4	2
エリート保存数	1	0
突然変異率	0	0.2
突然変異木率	0	0.1
交叉率	1.0	0.8
逆位率	0	0.1
移住個体数	100	
木の最大の深さ	6	
Pの値の変更率	0.05	

ゴミ拾い問題の適合度の各世代ごとの変化を図3に示す。縦軸は適合度、横軸は世代数である。進化の速さ、最終的な適合度のどちらにおいても GP_{CN_CP} , GP_{CN_IL} が GNP_{CN} や GP_{CN} より良い結果となった。特に、最適なPの獲得手法を導入した $GP_{CN_CP}(e)$, $GP_{CN_IL}(e)$ では、最も良い適合度を示している。

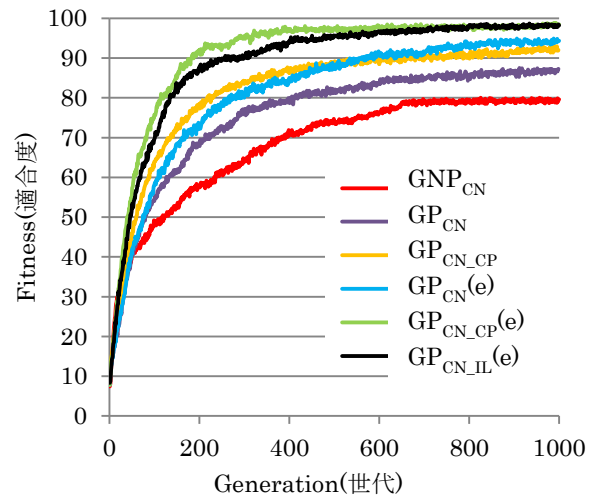


図3 ゴミ拾い問題の結果 (C=10, P=25)

B. Santa Fe Trail 問題

Santa Fe Trail 問題では、エージェントが効率よくフィールド内のすべての餌を拾う行動規則を獲得することを目標としている。Santa Fe Trail 問題のフィールドを図4に示す。フィールド




図4 Santa Fe Trail 問題のフィールド

ドは、縦 32×32 の二次元格子平面で構成される。また、フィールド上には、エージェントが 1 体、餌が 89 個配置されている。なお、エージェントと餌は、決められた場所に配置されている。エージェントは、1 ステップで前方に 1 マス動くか、左右のどちらかに 90 度回転することができる。また、餌のあるマスに到達すると餌を食べることができる。エージェントが 200 ステップ以内に食べることができた餌の数を適合度とする。適合度の最大値は 89 である。

Santa Fe Trail 問題における判定ノードと処理ノードの機能を表 5 に示す。種別は、0 が非終端ノード（判定ノード）、1 が終端ノード（処理ノード）を示す。また、実験に使用した GNP_{CN} のパラメータを表 6 に示す。 GP_{CN} 、 GP_{CN_CP} および GP_{CN_IL} のパラメータはゴミ拾い問題と同じである。

表 5 非終端ノードと終端ノードの機能

種別	機能 (エッジ数)
0	前方に餌が有るかどうかの判定。(2)
0	x を実行して y を実行する。(1)
0	x を実行して y を実行し、z を実行する。(1)
1	前方へ 1 セル進む。(1)
1	右へ 90 度回転。(1)
1	左へ 90 度回転。(1)

表 6 GNP_{CN} のパラメータ

最大世代数	1000
個体数	300
ノード数	12
交叉率	0.1
ノード接続変更率	0.01
調整ノード数	10

Santa Fe Trail 問題の適合度の各世代ごとの変化を図 5 に示す。縦軸は適合度、横軸は世代数である。Santa Fe Trail 問題では、最適な P の獲




図 5 Santa Fe Trail 問題の結果 (C=10, P=20)

得手法を導入した $GP_{CN}(e)$ と $GP_{CN_CP}(e)$ が、 GNP_{CN} や GP_{CN} よりも進化の速さおよび最終的な適合度においてよい結果となった。これは、最適な P の獲得手法を取り入れることで GP_{CN} 、 GP_{CN_CP} の探索効率が向上したためだと考えられる。しかしながら $GP_{CN_IL}(e)$ は、数世代足らずで 18 程度の適合度で進化が停滞している。これは、個性尊重の島での多様性に重点を置いた探索方法がうまく機能していないことが原因として考えられる。

V. おわりに

本研究では、従来手法である GNP_{CN} 、 GP_{CN} と、提案手法である GP_{CN_CP} 、 GP_{CN_IL} の比較実験を行った。ゴミ拾い問題において、提案手法である GP_{CN_CP} 、 GP_{CN_IL} が、進化の速さと最終的な適合度の値で従来手法より良い結果となった。これは、条件付確率や島モデルを取り入れることによって、局所解に陥りにくくなったことが考えられる。また、最適な P の獲得手法を導入することにより、適合度が向上することも示された。Santa Fe Trail 問題では、最適な P の獲得手法を導入した $GP_{CN}(e)$ と $GP_{CN_CP}(e)$ の進化の速さならびに最終的な適合度の値が従来手法よりも良い結果となった。しかしながら $GP_{CN_IL}(e)$ は、数世代程度で低い適合度のまま進化が停滞してしまった。個性尊重の島で多様性が維持できなかったことが原因だと考えられる。

本研究における今後の課題として、 GP_{CN_IL} のサブ集団の改良が挙げられる。比較実験により有効性の示された条件付き確率による個体生成を導入する予定である。

参考文献

- [1] 丹治信, 伊庭斉志, 「木構造のランダムサンプリングによる GP の個体生成手法の提案と評価」, 電気学会論文誌 Vol.130-C, No.5, pp. 775-781, 2010.
- [2] Toshiyuki Morioka, Hiroaki Ueda, Kenichi Takahashi, "Efficient Evolutionary Learning of Agent Behavior by Genetic Programming Using the Conditional Probabilities," *Proc. of 12th International Symposium on Advanced Intelligent System 2011 (ISIS2011)*, pp.342-345, 2011.

問い合わせ先

〒731-3194 広島市安佐南区大塚東 3-4-1

広島市立大学大学院 情報科学研究科 知能工学専攻

伊藤 崇