

集中多段交叉を用いた分散遺伝的アルゴリズムによる 離散的最適化問題の解法

Distributed Genetic Algorithm with Centralized Multiple Crossover
Applied to Discrete Optimization Problems

水田 伯典

Takanori MIZUTA

Abstract: This paper proposes a new method of genetic algorithms (GAs) for discrete optimization problems. For discrete optimization problems, the performance of Distributed GAs (DGAs) is not so good. We propose a method of increasing the performance of PDGAs. The features of the proposed method are multiple crossover operations applied to the elite genes and DGA without migration. The experiments on Job-shop Schedule Problems showed that the proposed method has a better performance than the conventional GAs, and the method provides an efficient parallel scheme in GAs for discrete optimization problems.

1 はじめに

連続最適化問題において、分散遺伝的アルゴリズム (Distributed Genetic Algorithms: DGA) は単一母集団 GA (Single Population GA: SPGA) と比較して高品質の解が得られると報告されている¹⁾。しかしながら、離散的最適化問題における性能についての報告は少なく²⁾、その性能は明らかとなっていない。そこで、本研究では離散的最適化問題の中からジョブショップスケジューリング問題 (JSP) を取り上げ分散 GA の性能を検証する。連続最適化問題とは異なり、離散的最適化問題に対しては PDGA の性能は良好ではない。そこで、離散的最適化問題に対して有効な分散 GA における新手法の提案を行う。

2 JSP に対する分散 GA の性能

JSP に対する分散 GA の性能を検証するため、単一母集団 GA と分散 GA の数値実験における性能比較を行う。実験では、交叉法に Inter-Machine JOX³⁾ を、突然変異には Job-Based Shift Change³⁾ を用い、実行可能解を得るため GT 法⁴⁾ による強制を行った。また、世代交代モデルには CCM⁵⁾ を適用し、CCM における生成子個体数は 20 とした。GA のパラメータは、母集団サイズ 800、交叉率 1.0、突然変異率 0.1、移住率 0.1、そして移住間隔 10 世代とした。実験は、最適解を得るか、評価計算回数が 100 万回に達した時点で打ち切った。対象問題を FT10 問題⁶⁾ として実験を行い、100 回試行した結果の適合度平均値 (avg) と最適解取得回数 (opt) を Table 1 に示す。表中の DGA n とあるのは、分散 GA におけるサブ母集団数が n であることを示す。

分散 GA の性能は、サブ母集団数が多くなるにつれて

Table 1 Performance of SPGA and DGA

Method	avg	opt/trial
SPGA	930.69	87/100
DGA 4	930.66	88/100
DGA 10	931.59	73/100
DGA 20	932.24	65/100
DGA 40	934.18	35/100
DGA 80	937.84	11/100

悪化していることがわかる。この原因としては、サブ母集団内の個体数の減少が考えられる。分散 GA は各サブ母集団が独自に解の成長を行うため、サブ母集団数を増やすことで母集団全体の多様性がより高くなることが期待できる。しかし、各サブ母集団内の個体数が減少するために、サブ母集団内での多様性の低下が速まり解の成長が止まってしまう可能性がある。分散 GA では、移住操作によりこの問題は解消されると期待できる。しかし、先ほどの実験で用いた移住パラメータは移住が少ない設定であり不適切であった可能性がある。

そこで、移住率を 0.1, 0.2 および 0.5、移住間隔を 2, 5, 10 および 20 世代として再度実験を行った。各サブ母集団数に対し、最良の移住パラメータとなった実験結果を Table 2 に示す。なお、表における param の列は最良の結果を得た試行の移住に関するパラメータ値であり、I が移住間隔を、R が移住率を示す。

サブ母集団数が 4 のものを除いては、移住率 0.5 の試行が最良の結果を示した。また、移住間隔についても短い方が性能が高くなる傾向にある。これらのことから、サブ母集団数を多くした場合でも、移住個体を多くし移住間隔を狭める、すなわち移住を多く行えば比較的良好

Table 2 Performance of SPGA and DGA (Best Param.)

Method	avg	opt/trial	param	
SPGA	930.69	87/100	-	
DGA 4	930.57	89/100	I2	R0.2
DGA 10	930.67	88/100	I5	R0.5
DGA 20	930.87	86/100	I10	R0.5
DGA 40	931.14	79/100	I2	R0.5
DGA 80	931.88	66/100	I2	R0.5

な性能が得られることがわかる。

しかしながら、移住パラメータ調節後の分散 GA においても単一母集団 GA の性能と大きな差はない。このことは、分散 GA によって母集団全体の多様性を維持することができても、移住によって適切な情報交換を行い性能を向上させることができていないことを示している。

一方、連続最適化問題の場合にはサブ母集団数を多くすることで性能が向上すると報告されている¹⁾。この点が離散的最適化問題と連続最適化問題の相違である。

3 集中多段交叉

3.1 分散 GA の問題点

離散的最適化問題は連続最適化問題とは異なり、問題に特化した染色体のコーディング法や交叉法を用いることが多いため、部分解が他の個体に受け継がれにくい。また、対象問題の制約条件によっては、大きな部分解が存在しないことも考えられる。

このことから、離散的最適化問題における分散 GA の問題点は、移住を行っても適切な情報交換がなされにくい点にあると考える。移住によりサブ母集団間での個体の移動が行われるが、あるサブ母集団から良好な個体が移住したとしても、移住先のサブ母集団でそれが有効に利用される(ここでは適切な交叉が行われることを指す)かどうか分からないためである。また、探索の中盤以降は遠すぎる個体同士の交叉は良好な子を生成しにくい傾向にあるため²⁾、各サブ母集団において有力な情報を持った個体が移住しても、その個体の性能に近い性質の個体との交叉が行われなければ、有効に活用されない可能性が高い。

これらのことから、離散的最適化問題においては移住による情報交換だけでは、分散 GA の性能が十分に引き出されないと考える。

3.2 集中多段交叉の提案

本節では、前節における問題点を解消する新たな手法、集中多段交叉 (Centralized Multiple Crossover: CMX) の提案を行う。CMX では各サブ母集団のエリート個体による情報交換を効率的に行うため、各サブ母集団から

エリート個体を含む数個体を抽出し、交叉処理を連続して行う。また、CMX によってサブ母集団間の情報交換が行われるため移住操作は行わない。Fig. 1 に CMX を用いる GA 操作の流れを示す。

CMX を行う GA では、GA の開始から CMX 適用まで、移住を行わない分散 GA である iDGA (isolated DGA) を行う。その後、CMX を適用する。

CMX は次の 4 つの操作からなる。

1. 交叉島の初期化
2. 交叉対象個体群の選択
3. 対象個体による多段交叉
4. 交叉島個体を分散 GA 母集団へ戻す

まず、CMX を適用する個体群を交叉島に移動させる。ここで、交叉島とは分散 GA を行っているサブ母集団群とは別に CMX 適用時のみ存在するものである。交叉島に集められる個体は、各サブ母集団から半数の個体をランダムに選択したものとする。ただし、その中には必ず各サブ母集団のエリート個体が含まれるものとする。

次に、交叉島から交叉対象となる個体群を選択する。この操作は、次の連続交叉を行うための親個体候補の選択にあたる。交叉対象の個体としては、交叉島に集められた各サブ母集団からの個体群より、それぞれ 2 個体ずつを選択する。この 2 個体の中には一定の確率でエリート個体が選択されるようにして、情報交換の効率を高めるようにする。

次に選択された交叉対象個体を用いて交叉を行う。この交叉において親個体として選択される 2 個体は、必ず異なるサブ母集団からのものであるようにする。また、交叉によって生成される子個体と親個体の生存選択は OCM に基づく操作を行う。この交叉は指定回数連続して行い、その間は交叉対象個体を変えずに同じ個体群から親個体を決定する。この一連の交叉処理を多段交叉と呼ぶ。1 回の多段交叉終了後、次の多段交叉を行う場合

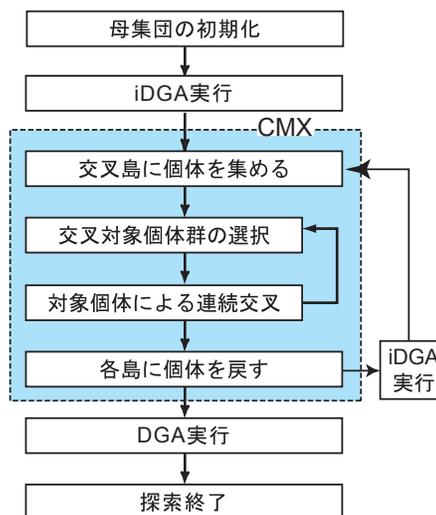


Fig. 1 Flow of DGA with CMX

には交叉対象を再度選択し直す。

最後の多段交叉終了後、交叉島の個体を元のサブ母集団に戻し CMX を終了する。

CMX は複数回適用することが可能であり、その場合には最後の CMX が終了するまで通常の探索には iDGA を行う。最後の CMX が終了した後は移住を行う通常の分散 GA を行い探索を終了する。

3.3 集中多段交叉の特徴

CMX の特徴をまとめると次のようになる。

- [特定個体群への連続した複数回の交叉]
CMX は交叉島の個体から交叉対象個体群を選択し、その個体群を用いて交叉を連続して行うため、交叉対象個体の高速な進化が期待できる。
- [エリート個体重視]
交叉島には必ず各サブ母集団のエリート個体が含まれ、交叉対象個体群にエリート個体が含まれやすいため、エリート個体による探索が重点的に行われる。これにより、各サブ母集団からの有力な個体情報が交換され、多段交叉実行段階での効果的な探索が期待できる。
- [移住を行わない]
CMX を用いた探索は移住を行わないため、各サブ母集団はそれぞれ独自に進化する。そのため、CMX では多様な個体による交叉を実行することが可能になると期待できる。
- [実行環境への柔軟な応用性]
CMX は交叉法や GA のモデルに依存することなく適用可能である。基本的に、分散 GA に適用できるものであれば採用できるため、既存の環境における応用が容易である。

逆に、CMX を行うことで次のような問題が発生すると考えられる。

- [CMX 独自のパラメータ設定]
CMX には実行開始世代・回数・間隔、多段交叉適用回数、多段交叉中の交叉実行回数、交叉対象選択時のエリート個体選択率などの新たなパラメータが存在する。この設定が GA の性能に大きく影響を与えるため、多くの予備実験が必要となる。
- [交叉法に対する依存性]
CMX にはどのような交叉法も適用可能である。しかし、移住を行わずに交叉島から選択された個体群に交叉を連続して行うことで情報交換を行っているため、親の形質を大きく破壊するような交叉法を適用すると CMX が有効に機能しない可能性がある。よって、CMX の性能は交叉法の性質に大きく依存すると考えられる。

• [サブ母集団数の設定]

CMX は多くのサブ母集団から多様な個体を集め、効率の良い交叉を行うことで、移住よりも高い効果を得ようとする手法であるため、サブ母集団数を多くしなければ高い性能は得られないと考えられる。

このことから、CMX を適用する際には用いる交叉法とサブ母集団数の設定に考慮する必要があるといえる。

4 CMX の性能

前節で提案した CMX の性能を、単一母集団 GA および分散 GA と比較することで検証する。数値実験で用いた CMX の設定を以下に示す。

- CMX 開始は 10 世代目
- CMX の実行は 8 回で 5 世代ごと
- CMX 中の評価計算回数が 8 万になったら終了
- 多段交叉中の交叉回数は 2 回
- CMX 中の交叉では子個体を 20 個生成
- エリート個体選択率は 50%

その他のパラメータおよび環境は 2 節で用いたものと同じとした。対象問題を FT10 問題⁶⁾として実験を行った結果を Table 3 に示す。

Table 3 Performance of CMX and conventional GAs

Method	CMX		Conventional	
	avg	opt	avg	opt
SPGA	-	-	930.69	87
DGA 4	930.83	86	930.57	89
DGA 10	930.85	86	930.67	88
DGA 20	930.53	90	930.87	86
DGA 40	930.43	93	931.14	79
DGA 80	930.27	95	931.88	66

表において、CMX の列は CMX を使用した GA の性能を、Conventional の列は 2 節で示した通常の GA の性能を示している。CMX を用いた GA の性能は、サブ母集団数が 20 以上のとき分散 GA および単一母集団 GA の性能を上回っている。CMX の性能は、サブ母集団数が多いほうが良好であり、特にサブ母集団数を 80 とした場合に最高の性能を示している。一方、サブ母集団数が 10 以下の場合には通常の分散 GA よりも性能が悪い。この原因は 3.3 節で述べたように、サブ母集団数が少ないと交叉島に多様な個体が集まらず、また、交叉対象個体が少なくなるため、CMX における交叉の効率が悪くなるからである。

この結果から、サブ母集団数を多くした上で CMX を適用すれば、分散 GA における個体の分散効果が有効に活用され解の成長が効果的に行われていると考えられる。このことを検証するため、最適解と同じクリティカ

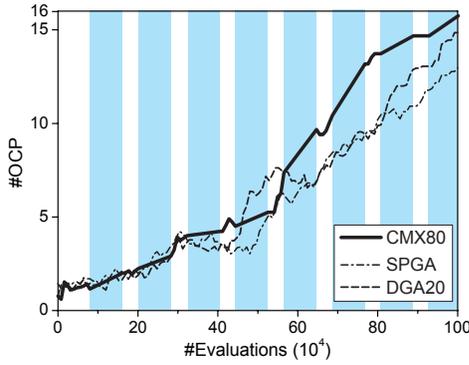


Fig. 2 Number of OCP of each evaluation time (ft10)

ルパスの連続が解の中にどの程度含まれているのかを調査した。JSPにおいて、クリティカルパスはスケジュールの中でも重要な要素である。また、クリティカルパスは前後の作業とのつながりが強いいため、スケジュール中の順序を調べるのではなく、この連続が解の中に含まれているかどうかを調査した。最適解におけるクリティカルパスの連続を最適クリティカルペア (OCP) と呼び、OCP 数の推移によって、部分解の成長を数値としてとらえる。先の実験における最良解の OCP 数を調査した結果を Fig. 2 に示す。

3つの手法において OCP 数は探索中盤まではほとんど差がないが、探索後半において CMX での OCP 数の増加が単一母集団 GA および分散 GA よりも大きいことがわかる。特にその増加は、CMX の実行段階 (図中の灰色箇所) において顕著であることから、探索後半以降の CMX が効果的に機能しているといえる。

次に対象問題を orb1 問題⁷⁾として CMX の性能調査を行った。100 試行結果の最適解取得率を Fig. 3 に示す。

orb1 問題に対する CMX の性能はサブ母集団数を多くするに従って大きく向上している。サブ母集団数 200 の時の CMX が全試行中もっとも性能が高く、CMX ではサブ母集団数を増やすに従って性能が向上していることがわかる。一方、分散 GA ではサブ母集団数を増やしても性能が向上する保証は得られない。ft10 問題と同様、CMX 適用時にはサブ母集団数を多くした方が性能が向上する。この原因を考察するため、OCP 数の推移を調査した。

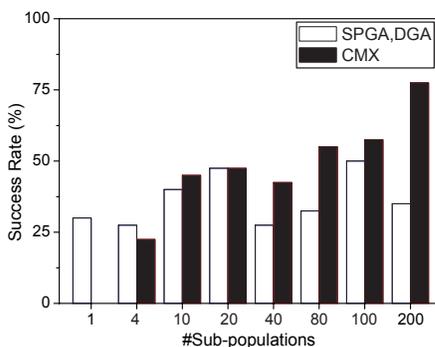


Fig. 3 Success Rate of orb1 on CMX and DGA

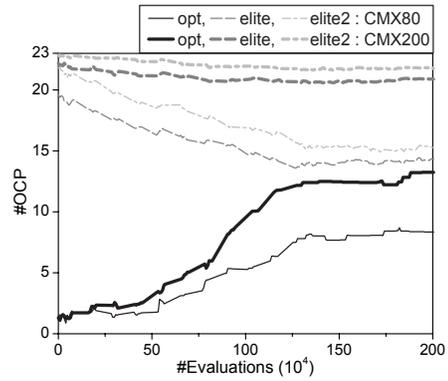


Fig. 4 Number of OCP of each evaluation time (orb1)

Fig. 4 はサブ母集団数 80 および 200 の最良解、各島のエリートおよび各島の 2 つのエリートの OCP 数の推移を示す。サブ母集団数が 80 の場合には各島のエリート個体中の OCP 数が減少している。このことが原因となって探索中盤以降、サブ母集団数 200 の場合と比較して OCP 数の増加がわずかにとどまっている。

このことから、CMX を用いる場合には、サブ母集団数を増やし、性能が良く多様な個体を集めることが重要であり、その理由は、最適解を構成する要素を多く集めることが可能となるからであるといえる。

5 おわりに

本研究では、離散的最適化問題に対する分散 GA における新たな手法、集中多段交叉 (CMX) の提案とジョブショップスケジューリング問題での性能評価を行った。数値実験の結果、CMX は従来手法よりも高い性能を得られることがわかった。

参考文献

- 1) 三木光範, 廣安知之, 畠中一幸, 吉田純一. 並列分散 GA による計算時間の短縮と解の高品質化. 日本計算工学会論文集, 2000.
- 2) 池田心, 小林重信. 生得分離モデルを用いた GA と JSP への適用. 人工知能学会誌, Vol. 17, No. 5, pp. 530-538, 2002.
- 3) 小野功, 小林重信. Inter-machine JOX に基づく JSP の進化的解法. 人工知能学会誌, Vol. 13, No. 5, pp. 780-790, 1998.
- 4) B. Giffler and G. Thompson. Algorithms for solving production scheduling problems. *Operations Research*, Vol. 8, pp. 487-503, 1960.
- 5) Isao Ono, Yuichi Nagata, and Shigenobu Kobayashi. A Genetic Algorithm Taking Account of Characteristics Preservation for Job Shop Scheduling Problems. *Proc. of the International Conference on Intelligent Autonomous Systems 5*, pp. 711-718, 1998.
- 6) H. Fisher and G.L. Thompson. Probabilistic learning combinations of local job-shop scheduling rules. in *Industrial Scheduling*(eds. by Muth, J.F. and Thompson, G.L.), pp. 225-251, 1963.
- 7) D. Applegate and W. Cook. A computational study of the job-shop scheduling instance. *ORSA Journal on Computing*, Vol. 3, pp. 149-156, 1991.