

論文要旨

本論文では、離散的最適化問題に対して有効な分散遺伝的アルゴリズム(分散GA)の新しい手法を提案する。分散GAは、連続最適化問題において良好な性能を示すことがわかっている。しかしながら、離散的最適化問題に関しては、単一母集団GAにおいては多くの研究がなされているが、分散GAにおいては、その性能は明らかになっていない。本論文では、代表的な離散的最適化問題である巡回セールスマン問題を対象として、分散GAの性能を検証する。その結果から通常分散GAにおける問題点を指摘し、問題点を解消する新しい手法を提案する。提案手法、CMX (Centralized Multiple Crossover) は、連続して複数回の交叉のみを行う点、移住を行わない分散GAを適用する点に特徴がある。CMXと分散GAの性能を比較した結果、巡回セールスマン問題に対して提案手法は高い性能を示した。

エリート解の集中的な交叉メカニズムを持つ 分散遺伝的アルゴリズムの TSP における 解探索性能の検討*

三木 光範[†]・廣安 知之[†]・花田 良子[‡]・水田 伯典[‡]

Distributed Genetic Algorithm with Centralized Multiple Crossovers Applied to Traveling Salesman Problems*

Mitsunori MIKI[†], Tomoyuki HIROYASU[†], Yoshiko HANADA[‡] and Takanori MIZUTA[‡]

This paper proposes a new method of genetic algorithms (GAs) for discrete optimization problems. For continuous optimization problems, it has been reported that distributed genetic algorithms (DGAs) show the higher performance than conventional GAs. However, for discrete optimization problems, the performance of DGAs has not been clear so far. In this paper, we propose a new approach in DGAs to discrete optimization problems. The proposed method is based on the multiple crossovers applied to the population consists of offsprings from elite individuals in distributed subpopulations (Centralized Multiple Crossover: CMX). We examine the performance of a conventional GA, DGA and proposed method for a typical discrete optimization problem, the Traveling Salesman Problem (TSP). The experiments showed that the proposed method provides better performance than the conventional DGA.

1. 緒言

近年, 対象問題の大規模複雑化に伴い, 進化的戦略を用いた手法が注目を集めている. その代表的なものに遺伝的アルゴリズム (Genetic Algorithms: GAs) がある.

GA は生物の遺伝と進化を模擬したアルゴリズムであり, ヒューリスティック法とランダム探索法を有効に組み合わせた手法である [1]. 現在, GA は確率的探索, 学習, 最適化などに広く応用されている [2-4].

GA の解探索能力を向上させる方法として Minimal Generation Gap (MGG) [5] などの世代交代モデルの利用, Linkage の同定とその情報を利用した探索手法 [6,7], 実数値 GA [8] など様々な手法やアルゴリズムが提案されている. その中の一つに, 母集団を分割する

島モデルの分散 GA (Distributed Genetic Algorithms: DGAs) がある. 分散 GA では, 母集団を複数のサブ母集団 (島) に分割し, 各サブ母集団ごとに独立に遺伝的操作を行い, 一定期間ごとに異なるサブ母集団間で個体情報を交換する移住と呼ばれる操作を行う [9]. 本来は並列モデルの一つとして提案されたが [10], 近年ではその探索能力の高さにも注目されている [11-14]. 連続最適化問題において, 分散 GA は単一母集団 GA (Single Population GA: SPGA) と比較して性能が高い [9,11,14]. 一方, 離散的最適化問題においては, 単一母集団 GA を用いた研究は多いが [15-20], 分散 GA を用いた研究は少ない [12,13,21]. その理由として, 離散的最適化問題に対する分散 GA の性能が良くないことが考えられる. 本研究では, 離散的最適化問題における分散 GA の性能を高める新手法を提案し, その性能の検証および考察を行う. なお, 本研究では, 離散的最適化問題の中から巡回セールスマン問題 (Traveling Salesman Problem: TSP) を対象とした. 巡回セールスマン問題はプリント基板素子配置問題や VLSI の設計, X 線結晶構造解析のような問題に应用することが可能であり, この問題を解くアルゴリズムによって多くの類似のクラスの離散的最適化問題を解くことができる [22].

* 原稿受付 1995年8月1日

[†] 同志社大学 工学部 Faculty of Engineering, Doshisha University; 1-3, Tatara-Miyakodani, Kyotanabe city, Kyoto 610-0394, JAPAN

[‡] 同志社大学 大学院 工学研究科 Graduate School of Engineering, Doshisha University; 1-3, Tatara-Miyakodani, Kyotanabe city, Kyoto 610-0394, JAPAN

Key Words: Genetic Algorithm, Traveling Salesman Problem, Distributed Genetic Algorithm, Centralized Multiple Crossover.




Fig. 1 Performance of SPGA and DGA on eil51

2. TSPにおける分散GAの性能

TSPに対する分散GAの性能を検証するため、分散GAと単一母集団GAの性能比較を行う。ここでは、交叉法に枝交換交叉 (EXX)[19]を用い、突然変異には2-change法を用いて実験を行った。

TSPの交叉において、親個体の枝情報を子個体へ継承すること、すなわち形質遺伝性を考慮したものにEX[17]、サブツアー交換交叉 (SXX)[23]、およびEXXなど提案されている。このうちSXX, EXXは両親の枝を子個体に完全に継承することが保障されている、すなわち形質遺伝性に優れた交叉方法である[20]。EXXはSXXと比較して性能がよいと報告されている[24]。

以下、EXXを交叉法として利用するが、その他の交叉法として枝組み立て交叉 (EAX)を採用した場合も本論文の後半で検討する。各パラメータは、全母集団サイズ400、交叉率0.8、突然変異率 $0.4/L$ (L は染色体長)および移住率0.1とし、移住間隔は5世代とした。分散GAにおけるサブ母集団数は4および16とした。各サブ母集団内ではSimple GAを行い、それぞれでエリート個体を保存することとした。51都市問題(eil51)[25–27]に対する実験結果をFig. 1に示す。

Fig. 1は巡回経路長の世代ごとの履歴を30試行の平均値で示したものである。図においてDGA n はサブ母集団数を n とした場合の分散GAの結果を示している。一方、SPGAは単一母集団GAの結果である。

この結果より、分散GAでは探索の初期段階における解の改善が単一母集団GAと比較してきわめて早いことがわかる。また、サブ母集団数の増加とともにこの傾向は顕著となる。しかしながら、分散GAにおいても初期収束を起こしやすく、探索の後半では解の改善がみられない。この原因は、移住によって各サブ母集団のエリート解(巡回路)がほぼ同じ解となり、母集団全体としての多様性が失われていることによる。一部の連続最適化問題においては、突然変異によって解の改良ができるが、TSPのような離散的最適化問題においては、多峰性の連続最適化問題と同じく、最適解の染色体と探索中の最良解の染色体との間に大きな相違があるため、突然変異を用いても効果的な改善を行




Fig. 2 Comparison between global optimum(left) and convergence solution(right) on eil51

うことができないことが予備実験でわかっている。

この理由をFig. 2を用いて示す。Fig. 2左は、距離428.8の最適解であり、右は距離429.8の解である。2つの巡回路長の差はわずか1.0であるにもかかわらず、右図において太線で示しているように、9本もの異なる枝が存在している。このように最適解とそれに巡回路長が近い解の間に多くの枝の違いがあるため、突然変異を用いても、解を容易に改善することができない。なぜなら、突然変異がうまく機能して、一部の枝が最適解と同じものになったとしても、他の枝を構成することで巡回路長が長くなってしまうと、選択操作中で淘汰されてしまうため、その個体は次世代に残らないからである。このことから、解の探索には適切な交叉を用いて、より良好な巡回路を生成する必要があると考えられる[20]。しかし、先述のように探索後半においては全サブ母集団で類似の解に収束しているため、今回用いた交叉法によって最適解を得ることは困難であると言える。単一母集団GAにおいても、個体数を増やさなければ、探索の後半に個体の多様性を維持できないため、Fig. 1のように探索後半で解の改善が少なくなる。

以上のことから、TSPに対しては分散GAの性能は単一母集団GAと比較して向上しないことが分かる。

3. 分散GAの性能を高めるメカニズム

3.1 分散GAにおける問題点とその対処法

分散GAは、連続最適化問題に対しては単一母集団GAより性能が高い[11]。しかしながら、TSPのような離散的最適化問題においては良好な結果を得ることができない。その原因は、サブ母集団間での移住による交叉を用いても最適解を求めることが困難であるという点にあった。そこで、本論文で提案する新手法では、この問題点を解消する操作を取り入れる。

移住に基づく交叉を用いてもうまく最適解を探索できなかった原因は、探索後半に母集団全体の多様性が失われていたことにあった。また、突然変異による解探索では、選択によって淘汰されることが多いために、多様性を高めることができなかった。このことから、TSPでは良好な部分解を構成することは難しいが、その構成要素である枝をうまく組み合わせることによって、良質な解を生成することが可能であると考えられ




Fig. 3 Superimposed tours of elite genes from all islands

る [19,20]. これは, ある程度成長した個体の巡回路を重ね合わせることでわかる. 具体例を Fig. 3 に示す.

Fig. 3 は, 2 節で用いた 51 都市問題に対して移住を行わない分散 GA を行い, 800 世代目におけるサブ母集団のエリート個体 8 個の巡回路をすべて重ね合わせたものである. 最適解と同じ枝は太線で示した. この図から, 8 個のエリート個体を重ね合わせることで, 最適解を構成できることがわかる. すなわち, 各サブ母集団で成長したエリート個体を全て用いることによって, 最適解を構成する部分解は得られないが, 最適解を構成する最小要素が得られることがわかる.

このことから, 最適解を得るには, ある程度成長した各サブ母集団のエリート個体を用い, その構成要素である枝をうまく組み合わせればよい.

上記の方法を実現するには, ある程度まで成長した個体, すなわち最適解に巡回路長が近い解を得る必要がある. ただし, ここで得る複数の解は, 最適解の構成要素を集めるために, それぞれができるだけ異なっていることが望ましい. これは, GA においては, 多様性が維持された状態で解が求まっている状態のことをさす. この状態を作るためには, 2 つの手法が考えられる.

1 つめの手法は, TSP におけるヒューリスティック法である 2-opt 法 [22] を用い, その結果生成された巡回路を初期個体とする方法である. 2-opt は, 2 本の枝の組み替えを行い, 枝の長さが短くなれば解を更新するという操作の単純な繰り返しによる個体生成法である. そのため, 2-opt 法を用いれば必ずそれ以上改良できない解を生成することができるが, 生成される個体の多様性については保証されないという問題がある.

もう 1 つの手法は, 分散 GA において移住操作を行わない方法 (isolated DGA: iDGA) である. 移住操作を行わないことで, サブ母集団ごとの多様性は失われるものの, 母集団全体としては多様性が維持されることが期待できる. ただし, どの程度の iDGA を行うことで最適解に近い解にまで成長するかが明らかでない.

一般的に, 2-opt 法を用いると, ある程度性能の良い解を生成できることがわかっている [28]. また予備実験により, 2-opt 法の方が iDGA よりも多様性の高い個体群を得られることがわかったため, TSP に対しては 2-opt 法を用いて複数の解を得ることとする.




Fig. 4 Flow of the proposed method

最適解に巡回路長が近い解を生成した後は, その個体の持つ枝をうまく組み合わせることが必要になる. 具体的には TSP に対して性能の高い交叉法を用いて, 枝を組み合わせることで考えると考えられる. この際に選択操作を行うと, 個体の中で一部だけに含まれている最適解を構成する枝が組み合わせの途中で淘汰されてしまう可能性があるため, できるだけ選択操作による淘汰は行わないことが望ましい. ただし, 良好な個体が淘汰されてしまうことを避ける必要があるため, 最良個体を必ず残すような選択は必要となる. このようにして, 一定数の個体に対して交叉のみを複数回連続して行うことで, 最適解を構成する枝をうまく組み合わせる操作を行う.

3.2 提案手法の操作

提案手法は, 集中的に交叉のみ連続してを行う点に特徴がある. 提案手法を用いた GA の具体的な操作を Fig. 4 に示す.

まず, GA に用いる初期個体を 2-opt 法によって生成する. 次に, 交叉を連続して行うための個体群を集めた新たな島 (交叉島) を用意する. なお, 交叉島は GA を行っている島とは別のものである.

交叉島に集める個体は, 最適解の構成要素をできるだけ多く含むと考えられる個体を選ぶ必要がある. 一方で, 最適解を構成するためにも, 集めた個体群の多様性が高いことが望ましい. そのためには, 分散 GA における各サブ母集団から個体を抽出すればよいと考えられる. ここで, 各サブ母集団からどの個体を抽出すべきかが問題となる. 本論文では, 次の 3 種類の抽出法を考える.

- (1) 各サブ母集団からエリートのみ
- (2) 各サブ母集団からエリートと 2 番目に良好な解
- (3) 各サブ母集団のすべての個体

1 および 2 番目の場合には, 抽出される個体数が元の母集団サイズより小さいため, 交叉島の個体数が母集団サイズになるまで, 親個体を残す交叉を用いて子

を生成する．すなわち，親個体から2つの子個体を生成し，親個体と子個体をすべて交叉島の個体とすることで，交叉島の個体数が母集団サイズになるまで増やす．なお，上記の3つの手法のうち，どの手法が最善であるかは，4.3節において議論する．

その後，交叉島において交叉のみを連続して行い，1回の交叉ごとに親個体と子個体を完全に入れ替える操作を行う．この生存選択において，EXXのように交叉法の中に必ず良好な個体が残るような操作が含まれている場合には，親個体と子個体を入れ替えることで良好な解を生成することが可能となる．しかし，交叉によって解の性能が低下する可能性がある場合には，子個体と親個体の比較を行い最良の個体については必ず残すなど淘汰圧のできるだけ少ない手法で最良個体を残すような処理を導入する必要がある．

その後，各サブ母集団から抽出された個体数と同数の個体を交叉島からGAを行っているサブ母集団に移す．ここまでの一連の操作を集中多段交叉 (Centralized Multiple Crossover: CMX) と呼ぶ．

CMXを複数回適用する場合には，CMXを行った後，移住を行わない分散GA (iDGA) を行い，その後一定世代が経過した時点でCMXを行う．ここで通常の分散GAを行わずにiDGAを行っている理由は，次のCMXに適用する個体の多様性を上げるためである．最後のCMXを適用した後に，移住を行う通常の分散GAを行い探索を終了する．

本手法において，新たに設定しなければならないパラメータは次の4つである．

- (1) 最初のCMXを行うまでの世代数
- (2) CMXの適用回数
- (3) CMXの適用世代間隔
- (4) 1回のCMXにおける多段交叉回数

最初のCMXを行うまでの世代数については，以下の実験では0世代目とし，初期個体をそのままCMXに適用している．項目(2)~(4)のパラメータについては，対象問題ごとに定めているが，多段交叉回数については4.1節で検討し，CMX適用回数については4.2節で検討する．

4. パラメータの検討

提案手法にはいくつかのパラメータの設定が必要である．これらの影響を調査するために，通常の分散GAおよび提案手法を用いた分散GAに関する実験を行った．本節におけるすべての実験において，交叉率は0.8，突然変異率は $1.0/L$ とした．また，交叉法および突然変異は2節と同じものを用いた．CMXに適用する個体はそれぞれのサブ母集団のエリートのみとした．実験結果は40試行の平均値を示したものである．

Table 1 Performance of CMX for every multiple crossover times

Method	N=16		N=80	
	Error(%)	Rel.*	Error(%)	Rel.
DGA	1.25	0/40	2.89	0/40
M=5	1.00	3/40	2.54	0/40
M=10	0.89	2/40	2.33	0/40
M=20	0.86	1/40	2.24	0/40
M=50	0.54	6/40	2.13	0/40
M=100	0.62	5/40	1.64	0/40

* Reliability

4.1 CMXにおける多段交叉回数の影響

CMX中の多段交叉回数が解探索性能に与える影響を調べるため，多段交叉回数を5, 10, 20, 50および100として実験を行った．個体数は400，サブ母集団数は16および80とした．実験は評価計算回数が8万回となった時点で打ち切った．対象問題を150都市問題 (ch150)[25]とした結果をTable 1に示す．

この表に示した値は最適解との誤差 (Error Rate) および最適解を得た回数 (Reliability: Rel.) である．表中のDGAは通常の分散GAの結果であり，Mは多段交叉回数，Nはサブ母集団数を示す．

まず通常の分散GAとCMXを用いたGAの性能を比較すると，CMXを適用した場合の方が解の性能が高くなっていることがわかる．次にCMX中の多段交叉回数に注目すると，回数を多くした方が性能が高くなることからわかる．しかしながら，サブ母集団数を16とした場合，多段交叉回数を50とした場合の方が100とした場合よりも性能が高くなっている．このことは交叉回数を大きく増やしたとしても，大きな性能の向上は期待できないことを示している．

一方で，サブ母集団数が80の場合には，交叉回数を100とすることで性能が向上している．これは，サブ母集団数が多くなるとCMXの適用に多くの個体が集まるため，多段交叉による枝の組み合わせが機能しにくくなるのが原因であると考えられる．そのため，多段交叉回数を増やすと性能が向上しているが，この向上には上限があると考えられる．

実験より，多段交叉回数は多い方がよいと言える．しかしながら，多段交叉回数を大きく増やすと，CMXの適用回数を増やした場合に計算時間が大幅に増えてしまう．今後は，多段交叉回数を10として実験を行う．

4.2 CMXを複数回行った場合

次に，CMXを複数回適用した場合の性能を検討する．前節で定めたように，多段交叉回数は10とした．また，実験は評価計算回数が8万回となった時点で打ち切った．他のパラメータについては，4.1節と同様の

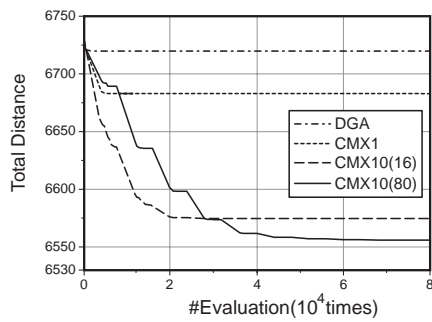


Fig. 5 History of tour length on CMX and DGA

ものを用いている．対象問題を 150 都市問題 (ch150) として実験を行った結果を Table 2 に示す．

Table 2 は，通常の分散 GA と CMX を 1, 2, 3, 5 および 10 回適用した場合の Error Rate を示している．なお，CMX の適用は 10 世代ごととした．表中の CMX n は CMX を n 回適用した結果を示す．

実験結果より，CMX の適用回数を多くするほど解の性能が良くなる傾向にあることがわかる．一般に，CMX の適用回数は多い方が解探索性能が高くなると言える．

次に CMX 適用の効果について検証する．Fig. 5 は，経路長の評価計算回数ごとの履歴を示したものである．CMX10 回適用時のものはサブ母集団数 16 および 80 とした場合について，分散 GA と CMX が 1 回のものについてはサブ母集団数が 80 の場合のみを示している．

Fig. 5 より，CMX を 10 回適用しサブ母集団数が 16 の場合には，20 世代目 (2 万評価計算) 以降，すなわち 3 回目の CMX が適用された後に解の改善が行われていないことがわかる．一方，サブ母集団数が 80 の場合には 20 世代目以降も解の改善が続いている．

以上のことから，CMX の適用回数は多い方が性能が向上するが，最適な適用回数はサブ母集団数に依存していることがわかる．これについては 4.4 節で考察する．

4.3 CMX への適用個体

3.2 節で示した，CMX への適用個体について検討する．パラメータは 4.1 節のものを用いた．また，CMX 適

Table 2 Performance of CMX for every execution times

Method	N=16		N=80	
	Error(%)	Rel.	Error(%)	Rel.
DGA	1.25	0/40	2.89	0/40
CMX1	0.89	2/40	2.33	0/40
CMX2	0.67	5/40	1.79	0/40
CMX3	0.83	2/40	1.25	0/40
CMX5	0.85	1/40	0.47	4/40
CMX10	0.67	5/40	0.38	8/40




Fig. 6 Performance of CMX for type of applied individuals

用世代間隔は 10 世代，多段交叉回数は 10 とし，CMX の適用回数は 5 回とした．実験は評価計算回数が 4 万回となった時点で打ち切った．対象問題を 51 都市問題 (eil51) とした実験結果を Fig. 6 に示す．

この図において ‘elite’ は CMX に対してエリート個体のみを適用した場合，‘elite+2nd’ はエリートと 2 番目に良好な個体を適用した場合，‘all’ は全個体を適用した場合の結果を示している．

CMX を適用すると，どの方法であっても通常の分散 GA の結果より高い性能を示している．また，エリートのみを CMX に適用した場合よりも，エリートと 2 番目に良好な解を適用した場合の方が性能が高い．

CMX による解の改善の効果は，良い方から順に，elite+2nd, elite, all となっている．しかし，性能の差は CMX 適用を繰り返すごとに減少している．elite および elite+2nd の場合には，2 回目までは CMX が効果的に機能しているが，それ以降の CMX では大きな解の改善は見られない．一方，すべての個体を適用した場合には，5 回目の CMX (40 世代目) でも解の改善が続いている．これは，CMX 適用の際に，個体の多様性を失うことがないため，遅い世代まで解の改善が続いているためであると考えられる．しかしながら，すべての個体を用いると，多段交叉による解の改善効果が小さくなるため，100 世代目においても，3 つの手法中もっとも結果が悪くなっている．このことから，CMX に適用する個体としては，エリート個体と 2 番目に良好な個体を選択するのがもっとも性能が良くなるといえる．

4.4 サブ母集団数の影響

サブ母集団モデルの場合，サブ母集団数は解探索に大きな影響を与える．そこで本節では，サブ母集団数が CMX の適用に与える影響について検討する．対象問題は，150 都市問題 (ch150) および 532 都市問題 (att532) とした．150 都市問題においては，全母集団サイズ 400 に対して，サブ母集団数を 2 から 200 まで変化させた．また 532 都市問題においては，全母集団サイズ 800 に対して，サブ母集団数を 2 から 400 まで




Fig. 7 Performance of CMX and DGA for every subpopulation size (ch150)




Fig. 8 Performance of CMX and DGA for every subpopulation size (att532)

変化させた．CMXの適用回数は10回，適用間隔は10世代とし，100世代まで探索を行った．その他のパラメータについては前節と同様の値を用いている．対象問題を150都市問題とした結果をFig. 7に，532都市問題とした結果をFig. 8に示す．結果は40試行の平均値である．

2つの図から，CMXの性能はサブ母集団数によらず分散GAよりも高いことがわかる．また，CMXを適用した場合，解の性能はサブ母集団数が増えるに従って向上している．ただし，532都市の場合にはサブ母集団数を100より増やした場合に性能が悪化している．

この原因は，次のように考えることができる．すなわち，ある程度までサブ母集団数を増やし，かつiDGAを適用して移住を行わないことにより，個体情報の交換が行われず，各サブ母集団が独自に成長し母集団全体の多様性が高まる．このことによって，CMXの適用後も探索の後半まで解の改善が続き，良好な結果につながったといえる．しかし，サブ母集団数をさらに増やした場合には，各サブ母集団における個体数が少なすぎるため，iDGAのステップにおける解の改善の効果が小さくなり，解の性能が悪化すると考えられる．今回の実験より，CMXを適用する場合には，各サブ母集団における個体数を10程度とした場合にもっとも性能が高くなることがわかった．

これらのことから，サブ母集団数は一般に多い方がCMXの性能が向上するが，これには上限値が存在し

ていると考えられる．

5. CMXの探索能力の検討

5.1 分散GAとの比較

提案したCMXの解探索能力を検証するため，いくつかの問題に対しても分散GAとの比較を行った．実験結果をTable 3に示す．

Table 3 Performance of CMX and DGA

Instance	Error(%)		
	DGA	N=16	N=80
att48	0.16	0.06	0.00
ber52	0.04	0.00	0.00
eil76	1.63	0.31	0.03
ch130	1.96	0.92	0.61
kroA200	2.88	0.92	0.69
pr226	0.46	0.03	0.00
gil262	3.64	1.78	1.70
lin318	2.92	1.81	1.67
pr439	3.06	1.55	1.38
att532	2.91	1.30	0.92

通常の分散GAの結果はサブ母集団数を16とした場合のものであり，CMXを適用した実験はサブ母集団数を16および80とした結果である．結果はすべて40試行の平均値を示している．全母集団サイズは，226都市問題までは400としているが，それ以降の問題については，262都市問題では500個体，318都市問題では600個体，439および532都市問題では800個体とした．この変更に伴い，262都市問題ではサブ母集団数を20に，318都市問題では75とした．

実験結果は最適解からの誤差を示している．すべての問題において，CMXを適用した場合の性能が分散GAの性能よりも高いことがわかる．このことから，CMXは問題によることなく有効であると考えられる．

5.2 他の交叉法の適用

前節までの実験は，交叉法として枝交換交叉(EXX)を用いていた．ここでは，異なる交叉法に対するCMXの性能について考える．そこで，EXXよりも性能が高いと報告されている枝組み立て交叉(EAX)[20]を用いてCMXの性能を評価する．

EAXはEXXと比較して，大域的な探索を行うことが可能であるため，EXXでは最適解の探索が難しかった問題に対しても，最適解にたどり着くことが可能となる[20]．

EAXの原著論文EAX[20]では世代交代モデルにER(Elitist Recombination)[29]を用いている．ここではCMXにおけるiDGAの世代交代モデルにERを用いたモデルとERとを比較する．以降，前者をCMX(ER，

EAX), 後者を ER(EAX) と記述する. なお, 前節までの実験および EAX の論文では 2-opt 法を用いているが, 本節では, CMX のメカニズムに EAX の性能を引き出す効果があるかの検証を行うため 2-opt 法は用いない. したがって, CMX(ER, EAX) では, まず, ある程度 iDGA で探索した上で CMX を適用する. 対象問題は 150 都市問題 (ch150), 226 都市問題 (pr226), 262 都市問題 (gil262), 439 都市問題 (pr439), 575 都市問題 (rat575) および 783 問題 (rat783) の 6 問題とした.

Table 4 に CMX(ER, EAX) および ER(EAX) において 30 試行の平均および最適回を得た回数を示す. これらは全母集団サイズを 300 に固定し, 評価計算回数は 262 問題までは 6.0×10^5 回, 439 問題および 575 問題については 7.2×10^5 回, 783 問題については 1.08×10^6 回とした結果である. なお, CMX を適用した実験はサブ母集団数を 30 としている. ER の交叉においては各両親に対し 10 回交叉を適用し子個体群を生成している.

Table 4 Comparison between CMX(ER, EAX) and ER(EAX)

Instance	CMX(ER, EAX)		ER(EAX)	
	Average	Rel.	Average	Rel.
ch150	6529.333	27/30	6536.267	16/30
kroA200	29368	30/30	29377.27	10/30
pr226	80372.27	27/30	80614.97	1/30
gil262	2378.233	27/30	2379.167	17/30
pr439	107224.7	25/30	109014.1	0/30
rat575	6775.9	0/30	6836.4	0/30
rat783	8813.667	5/30	9019.5	0/30

結果より, いずれの問題においても CMX(ER, EAX) は ER(EAX) と比較して良好な結果が得られていることがわかる. これより CMX のメカニズムを組み込むことにより, EAX の性能を高めることができると考えられる.

5.3 世代交代モデルの比較

前節では, 世代交代モデル ER に CMX を適用した結果, 性能が向上することがわかった. 本節では, 他の世代交代モデルとして CCM(Characteristics Collection Model)[30] との比較を行う. CCM は各親個体の形質をできるだけ次世代に引き継ぐように設計されたモデルであり, 形質遺伝性にすぐれた交叉と親和性が高いとされているモデルである [30]. 従って, EAX の性能を引き出すモデルと考えられる. そこで, 交叉に EAX を用い, CMX における iDGA に世代交代モデル CCM を適用したモデルと CCM を比較する. 以降, 前者を CMX(CCM, EAX), 後者を CCM(EAX) と記述する. なお, 前節と同様 2-opt 法は用いない. 対象問題は 150

都市問題 (ch150), 226 都市問題 (pr226), 262 都市問題 (gil262), 439 都市問題 (pr439), 575 都市問題 (rat575) および 783 問題 (rat783) の 6 問題とした.

Table 5 に CMX(CCM, EAX) および CCM(EAX) において 30 試行の平均および最適回を得た回数を示す. 全母集団サイズ, 評価計算回数等のパラメータは前節の実験で用いたものと同様である.

Table 5 Comparison between CMX(CCM, EAX) and CCM(EAX)

Instance	CMX(CCM, EAX)		CCM(EAX)	
	Average	Rel.	Average	Rel.
ch150	6528	30/30	6528	30/30
kroA200	29368	30/30	29368	30/30
pr226	80369	30/30	80369	30/30
gil262	2378	30/30	2378	30/30
pr439	107217	30/30	107217	30/30
rat575	6773.767	13/30	6773.53	14/30
rat783	8806.167	28/30	8806	30/30

Table 4 の ER(EAX) の結果と Table 5 の CCM(EAX) の結果を比べると, CCM は EAX の性能を大きく高める作用があることが分かった. 一方, Table 5 の結果から CCM を使った場合には CMX の効果は見られなかった. このことから, CMX と CCM はまったく異なるメカニズムであるにもかかわらず, 同じ効果をもたらすことが分かった.

5.4 CMX の性能に関する考察

前節までの実験において, CMX を適用した場合の性能が通常の分散 GA よりも高いことを示した. 本節では, CMX の性能がなぜ高くなっているのかを, 各個体が構成する枝に注目して考察する. なお, 本節の実験では交叉法として EAX を用いている.

Fig. 9 は, サブ母集団数を 16 および 80 とした CMX (適用回数 10 回) と分散 GA の最適枝数の推移を示したものである. 対象問題は 150 都市問題 (ch150) である. なお, 横軸には世代数ではなく, 1 個体あた

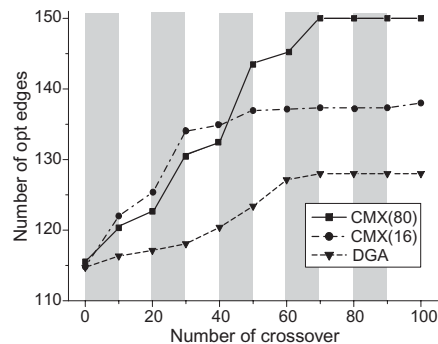


Fig. 9 History of opt-edge size on CMX and DGA

りに適用された交叉の回数を示している。すなわち、1世代に1回交叉が行われるため、通常の分散GAにおいては世代数と同じであるが、CMXを適用した場合には、1度のCMXによって10回の交叉が行われるため、交叉10回となる。図中でグレイの部分がCMX適用時にあたる。パラメータは前節と同様のものを用いている。縦軸は、母集団全体の個体の中で最適解の巡回路を構成する枝(以下、最適枝)をもっとも多く持っている個体の最適枝数を示している。よって、最良個体が最適解までたどり着いた場合には150となる。

サブ母集団数を80とした場合については、初めの10回の交叉が1回目のCMXを適用したものにあたる。この交叉の段階で、通常の分散GAと比較して最適枝数が大きく増加している。次の10回の交叉は、iDGAを行っている段階に当たり、分散GAの結果と比較して大きな違いはない。しかし次のCMX適用により、再び最適枝数が大きく増加している。さらに、3回目、4回目のCMXによって最適枝数が増加し、最適解である最適枝数150に達している。

一方、サブ母集団数が16の場合には、1回目および2回目のCMXでは、サブ母集団数を80とした場合と同じく最適枝数が通常の分散GAよりも大きく増加している。しかし、それ以降のiDGAおよびCMXにおいては、最適枝数の増加が見られなくなっている。交叉回数100回まで達しても、50回の値とほとんど同じとなっている。

これらのことから、交叉島に適切な個体が集められると、CMX中に交叉を繰り返すことで良好な個体を生成できているが、集められた個体によってはCMXを行っても性能を上げられないことがあるといえる。

6. おわりに

本論文では、分散GAを離散的最適化問題に適用するための新しい手法として集中多段交叉法(CMX)を提案した。TSPを用いて実験を行い、基本的な探索能力の検討、いくつかのパラメータ、交叉法および世代交代モデルなどの検討も実験を通じて検討した。その結果、提案手法は、TSPにおいて分散GAの性能を大きく向上させるメカニズムであることが分かった。

今後は、Jop Shop Scheduling問題など他の離散的最適化問題に適用し検討を行うこと、並列処理を行った場合の効率の検討などが課題である。

参考文献


- [1] J. H. Holland. Adaptation In natural and Artificial Systems. *University of Michigan Press*, 1975.
- [2] D. E. Goldberg. Genetic Algorithms in Search, Optimization and Machine Learning. *Addison-Wasley Publishing Company*, 1989.
- [3] 北野弘明. 遺伝的アルゴリズム. 産業図書, 1993.
- [4] 坂和正敏, 田中雅博. 遺伝的アルゴリズム. 朝倉書店, 1995.
- [5] 佐藤浩, 小野功, 小林重信. 遺伝的アルゴリズムにおける世代交代モデルの提案と評価. *人工知能学会誌*, Vol. 12, No. 5, 1997.
- [6] H. Kargupta. SEARCH, polynomial complexity, and the fast messy genetic algorithm, *IlligAL Report No. 95008, University of Illinois at Urbana-Champaign, Urbana, IL*, October 1995.
- [7] G. R. Harik. Linkage learning in via probabilistic modeling in the ECGA. *Technical report, IlligAL Technical Report*, No. 99010, 1999
- [8] 小野功, 佐久間 淳, 小林 重信. 単峰性正規分布交叉 UNDXを用いた実数値GAによる関数最適化人工知能学会誌 Vol.14 No.6(1999)
- [9] R. Tanese. Distributed Genetic Algorithms. *Proc.3rd International Conference on Genetic Algorithms*, pp. 434-439, 1989.
- [10] E. Cantú-Paz. A survey of parallel genetic algorithms. *Calculateurs Paralleles*, Vol. 10, No. 2, 1998.
- [11] 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.
- [12] I. Pinto Distributed Genetic Algorithms using DLL. *IEEE Int. Conf. On systems, Man, and Cybernetics*, pp.I-683-I688, 1999.
- [13] H. Horii, S. Kunifuji, T. Matsuzawa Asynchronous Island Parallel GA Using Multiform Subpopulations. *Lecture Notes in Artificial Intelligence 1585, Springer-Verlag*, 1999
- [14] T. C. Belding. The distributed genetic algorithm revisited. *Proc. 6th International Conference on Genetic Algorithms*, pp. 114-121, 1995.
- [15] D. Goldberg and R. Lingle, Jr. Alleles, Loci, and the Traveling Salesman Problem. *Proc. of 1st International Conference on Genetic Algorithms and Their Applications*, pp. 154-159, 1985.
- [16] J. Grefenstette, R. Gopal, B. Rosmaita, and D. Gucht. Genetic Algorithms for the Traveling Salesman Problem. *Proc. 1st International Conference on Genetic Algorithms*, pp. 160-165, 1985.
- [17] D. Whitley, T. Starkweather, and D. Fuquay. Scheduling Problems and Traveling Salesman: The Genetic Edge Recombination Operator. *Proc. 3rd International Conference on Genetic Algorithms*, pp. 133-140, 1989.
- [18] A. Homaifar, S. Guan, and G. Liepins. A new approach on the traveling salesman problem by genetic algorithms. *Proc. 5th International Conference on Genetic Algorithms*, pp. 460-466, 1993.
- [19] 前川景示, 玉置久, 喜多一, 西川示章一. 遺伝アルゴリズムによる巡回セールスマン問題の一解法. *計測自動制御学会論文集*, Vol. 31, No. 5, pp. 598-605, 1995.
- [20] 永田裕一, 小林重信. 巡回セールスマン問題に対する交叉: 枝組み立て交叉の提案と評価. *人工知能学会誌*,

Vol. 14, No. 5, pp. 848–859, 1999.

- [21] 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.
- [22] 山本芳嗣, 久保幹雄. 巡回セールスマン問題への招待. 朝倉書店, 1997.
- [23] 山村雅幸, 小野功, 小林重信. 形質の遺伝を重視した遺伝的アルゴリズムに基づく巡回セールスマン問題の解法. 人工知能学会論文誌, Vol.7, No.6, pp. 117–127, 1992.
- [24] 三宮信夫, 喜多一, 玉置久, 岩本貴司. 遺伝的アルゴリズムと最適化朝倉書店, 1998.
- [25] TSPLIB95. <http://softlib.rice.edu/softlib/tsplib/>. 1995.
- [26] E. L. Lawler, J. K. Lenstra, A. H. G. Rinnooy Kan, D. B. Shmoys. The Traveling Salesman Problem: A Guided Tour of Combinatorial Optimization. *John Wiley & Sons*, 1985.
- [27] G. Gutin .A. P. Punnen The Traveling Salesman Problem and Its Variants. *Kluwer Academic Publishers*, 2002.
- [28] D. J. Rosenkrantz, R. E. Stearns, and P. M. Lewis. An analysis of several heuristics for the traveling salesman problem. *SIAM Journal on Computing* 6, pp. 563–581, 1977.
- [29] D. Thierens, D. E. Goldberg Elitist Recombination: an integrated selection recombination GA *Proceedings of the 1st IEEE Conference on Evolutionary Computation*, pp. 508–5512, 1994.
- [30] I. Ono, S. Kobayashi A Genetic Algorithm Taking Account of Characteristics Preservation for Job Shop Scheduling Problems. *Intelligent Autonomous System 5*, pp.711-718(2000)


著者略歴

三木 光範 (正会員)




1978年大阪市立大学大学院工学研究科博士課程修了, 工学博士. 大阪市立工業研究所研究員, 金沢工業大学助教授を経て1987年大阪府立大学工学部航空宇宙工学科助教授, 1994年同志社大学工学部教授. 進化的計算手法とその並列化, および知的なシステムの設計に関する研究に従事. 著書は「工学問題を解決する適応化・知能化・最適化法」(技法堂出版)等多数. IEEE, 米国航空宇宙学会, 情報処理学会, 人工知能学会, システム制御情報学会, 日本機械学会, 計算工学会, 日本航空宇宙学会等会員. 超並列計算研究会代表. 経済産業省産業技術審議会委員.

廣安 知之



1997年早稲田大学理工学研究科後期博士課程修了. 同年早稲田大学理工学部助手. 1998年同志社大学工学部助手. 2001年同大学専任講師. 創発的計算, 進化的計算, 最適設計, 並列処理などの研究に従事. IEEE, 情報処理学会, 電気情報通信学会, 計測自動制御学会, 日本機械学会, 超並列計算研究会, 日本計算工学会各会員.

花田 良子



2002年同志社大学工学部知識工学科卒業. 同年, 同志社大学大学院工学研究科修士課程入学. 並列計算, 遺伝的アルゴリズムの研究に従事. 情報処理学会会員.

水田 伯典



2001年同志社大学工学部知識工学科卒業. 同年, 同志社大学大学院工学研究科修士課程入学. 並列計算, 遺伝的アルゴリズムの研究に従事. 情報処理学会, 人工知能学会学生会員.