

大規模 TSP を対話的応答時間内で最適化するための多段知能型 GA

櫻井 義尚[†] 小野山 隆^{††} 久保田 仙^{††} 中村 嘉宏[†] 鶴田 節夫[†]

提案する多段知能型 GA は、大規模巡回セールスマントラベル問題 (TSP)を対話リアルタイム応答時間内に専門家レベルの最適度で解くことを目的とする。GAにおいて最適化問題を効率的に解くためには問題固有の特性に従った探索をする必要があるが、これにより偏った探索になる可能性がある。提案する GA は、TSP に有効なヒューリスティックスあるいは知識を導入した新しい初期解生成、交叉、突然変異を用いることにより、効率的な探索を実現し、探索特性の異なる相補的性質を持つ GA を複数設計し、これらを組み合わせて用いることにより、探索の偏りを防ぎ、安定的に解を求める事ができる。

A Multi-step Intelligent Genetic Algorithm
to Interactively Optimize Large-scale TSP
Yoshitaka Sakurai[†] Takashi Onoyama^{††} Sen Kubota^{††}
Yoshihiro Nakamura[†] Setsuo Tsuruta[†]

To optimize large-scale distribution networks, solving about 1000 middle scale (around 40 cities) TSPs (Traveling Salesman Problems) within an interactive length of time (max. scores of seconds) is required. Yet, expert-level (less than 3% of errors) accuracy is necessary. To realize the above requirements, a Multi-step intelligent GA method was developed. This method combines a high-speed GA with an intelligent GA holding problem-oriented knowledge that is effective for some special location patterns. If conventional methods were applied, solutions for more than 20 out of 20.000 cases were below expert-level accuracy. However, the developed method could solve all of 20.000 cases at expert-level.

1. はじめに

物流の効率化は経済面からだけではなく、環境・社会面から見ても CO₂ や排気ガスの節減などにもつながるため重要な問題であり、多数の配送先と多数のトラックにより構成されるより大規模な配送ネットワークの最適化の要求が高まっている。

このような配送ネットワークの構築では、まず製品の製造を行う工場や、輸送の中継に用いるデポの配置、部品輸送用のトラック配置等の条件設定を人間が行う。次に輸送コストと CO₂ 等の排出量を算出して、経済面及び環境面から人間が総合的に評価する。これらの算出のためには、千近くの部品メーカーとデポ・工場を結ぶ数百の集配ルートを作成して走行距離を求める必要がある。このルートの最適性の評価には単純な走行コストだけでなく、社会面からの人間の判断が不可欠になる。このため、システムとしては、対話的な応答性能が要求される。

つまり、大規模な配送ネットワークにおける数百から千に及ぶ配送ルートを数十秒で作成しなければならない。1ルートあたりではルート生成を数十ミリ秒で行う必要がある。それぞれのルートの生成は数十都市の TSP(巡回セールスマントラベル問題、Traveling Salesman Problem)を解くのと等価である。ゆえに TSP に対して対話的な応答性と高い最適性の両方を可能とする近似解法が必要である。

人間の専門家は、数学的な最適解に対して 2～3% の誤差を出すことが多いが、それ以上の誤差を出し実用上の問題を起こすことはない。一方、従来の近似解法[1]を用いると、数学的な最適解を得られる確率は高いが、誤差を常に 2～3% 程度以下に出来る保証がない。このため、従来の近似解法は実用上、特に上記の問題への適用には適していない。TSP の厳密解法としては、Branch-and-cut 法 [2] や Dynamic Programming(DP)を用いた解法[3]が提案されているが、精度は高いが計算時間が長い。近似解法としては、Simulated Annealing (SA)法やタブーランプを用いる方式[4], [5]が提案されているが、計算時間が長く、対話的な応答性能が要求される問題には適していない。TSP の解法として

[†] 東京電機大学

Tokyo Denki University

^{††} (株)日立ソフトウェアエンジニアリング

Hitachi Software Engineering Co.,Ltd.

Lin-Kernighan(LK)法やその改良手法[6]が提案されているが、専門家レベルの最適度を常に保証することができない[7].

本研究では、TSP に有効なヒューリスティックスあるいは知識を導入した新しい初期解生成、交叉、突然変異を導入した複数の遺伝的アルゴリズム(Genetic Algorithm, GA)[8]を組み合わせることにより、多様な巡回拠点配置パターンにおいて、対話的応答時間内に専門家レベルの最適度で解くことを保証する近似解法を提案し、実験によりその有効性を検証する。

2. 多段知能型 GA (MIGA)

2.1. 多段知能型 GA

相補的な性質を持つ 2 つの GA を組み合わせることにより様々な巡回拠点配置パターンに対して、専門家レベルの最適性と対話的応答性を実現する多段知能型 GA (Multi-step Intelligent GA; MIGA)を提案する。

GA で効率的な最適化を行うためには、問題の特徴に合った GA のオペレータを利用する必要がある。そこで、TSP に有効なヒューリスティックスを GA のオペレータに組み込む。この手法は、主にシンプルで汎用性の高いヒューリスティックスを用いているため高速に最適化が行える 2opt 型 GA と計算コストは高いが最適化能力と局所最適解からの脱出効果の高いブロック型 GA の 2 つの異なる探索特性を持つ GA を組み合わせる事により、多様な巡回拠点配置パターンで局所最適解に陥るのを回避しつつ、高い応答性を保証する。具体的には、2 つの GA を独立に試行し、良い結果を採用する。

2opt 型 GA: ランダム NI 生成により初期集団を生成し、NI 型交叉、2opt 型突然変異により解の改善を行う。シンプルで汎用性の高いヒューリスティックスである 2opt 法を用いることにより、素早くツアーカーを改善する。しかし、局所最適解に陥るリスクも持っている。

ブロック型 GA: ランダム生成、挿入順制御 NI 生成を使うことにより高い最適度の初期集団を生成し、NI 型交叉により解の改善を行う。また、ブロック型突然変異によりツアーカーの局所的に最適化された部分を再構築し、局所最適解に陥ることを防ぐ。計算コストは高いが高い最適化が望めるヒューリスティックスである NI(Nearest Insertion)法を主に用いて

いる。これにより 2opt 型 GA とは違う探索特性を持つ。

2.2. 多段知能型 GA の構成要素

本解法では、解の候補となる個体は TSP におけるツアーカー(配送ルート)を表現する染色体を持ち、その遺伝子型は巡回する順番にノード番号(配送先の ID 番号)を並べた構造(各遺伝子はノード番号を表現する)になっている。各個体の評価(適応度)は、その世代の個体集団の中での最小のツアーカー長を L_{Min} とするとき、ツアーカー長が L の個体の適応度を $F=L_{Min}/L$ で計算する。この適応度に基づき、全個体(親個体集団と子個体集団)の中から適応度の高い順に次の世代への個体の選択を行う。また、たとえ適応度が低くても改善の機会を与えるため個体数の 10%はランダムに決定される。

(1) 初期集団生成:

局所最適解に収束するのを防ぎ、最適度の高い解を得るためにには、初期集団の多様性が重要になる。しかし迅速に高い最適度を得るためにには、初期集団の生成段階からある程度の最適化が必要になる。このため以下のように最適化の強さの違う 3 種類の方法を用いる。

a) ランダム生成

ノードの順序をランダムに並べることによりツアーカーを生成する。

b) ランダム NI 生成

ランダムな順序でノードを NI 法を用いてツアーカーに挿入していくことによりツアーカーを生成する。

c) 挿入順制御 NI 生成

専門家がツアーカーを生成するとき、彼らはたいてい全体のルートの概観を考えながら近いものから順に巡回する順番を決めていく。このような専門家の全体指向的な決め方をモデル化することにより、挿入順制御 NI 生成法は提案された。具体的には、以下の手順でツアーカーを生成する。

- ① NI 法でノードをツアーカーに挿入する場合の、ツアーカーの距離の増分値を求める。
- ② ①で求めた値と、ノードを挿入するリンクの長さに一定倍率を掛けた値を比較する。
- ③ ①で求めた値が小さい場合にだけ NI 法でノードをツアーカーに挿入する。
- ④ ①から③の操作を、③の条件を満足するノードが無くなるまで繰り返す。
- ⑤ ツアーカーに挿入されていないノードがあれば、先の

倍率(ステップ②の倍率)を大きくして、再度①から④の操作を繰り返す。

(2) 交叉オペレータ(NI型交叉):

交差で二つの親の良い形質を子に継承して GA で迅速な解の収束を実現するために、NI 法を用いた交差オペレータ NI 型交叉を提案する。これは図 1 のような手順で、親 1 の交叉点より前の部分ツアーやこれに除いた親 2 のノードを NI により挿入することにより新しい個体を生成する。

この交叉オペレータは、二つの親個体に含まれているノードの順序を子個体に継承でき、GA の収束性を高めることができると考えられる。

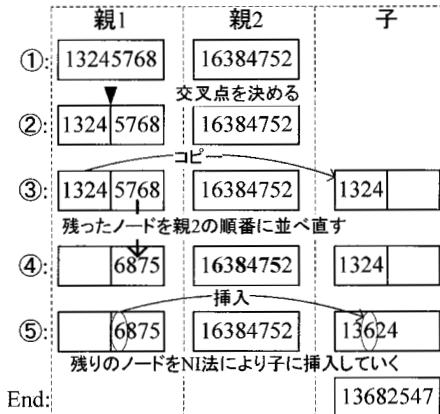


図 1. シミュレーションの過程

(3) 突然変異オペレータ:

a) 2opt 型突然変異

これはランダムに選択した遺伝子を局所探索法である 2opt 法で改良する方式である。まず、遺伝子が表すツアーや中の二つのリンクを取り出して、その二つのリンクを交換してツアーや長を評価する。もしリンクの交換でツアーや長が短くなれば、二つのリンクを交換する。このリンクの交換をツアーや長の改善がなくなるまで繰り返す。

b) ブロック型突然変異

2opt 型突然変異は効率的にツアーやを改良でき短時間に良好な解を得ることができる。しかし、このような効率的な探索は逆に局所最適解に陥る危険性を高めてしまう。より最適性の高い解を得るためにには局所最適解から脱出するためにツアーやの一部を破壊する操作が必要である。このため、次のブロック突然変異を提案する。これは、まずツアーや中の 1 つのノードをランダムに選択して、そのノードの近

傍に含まれるノードをツアーやから削除する。この近傍のサイズもランダムに選択する。次に、これらのツアーやから削除したノードを再び NI 法で再挿入してツアーやを再構築する。

3. 評価実験

3.1. 評価実験の設定

本実験では、Intel Pentium II(450MHz)プロセッサと 256MB のメモリを装備している PC を実験に使用し、C 言語によりプログラムを作成した。

ターゲットとしている配送ネットワークでは、一台のトラックでは一日に 40 拠点以上巡回することは不可能なので、40 都市の TSP で各解法の評価を行う。現実には様々な拠点の配置が発生するために、40 都市をランダムに配置した 20,000 個の異なる巡回拠点配置パターンを用意した。そして、各解法の効果を評価するために、それぞれの解法で 100 回、テストパターンを解き、数 10 ミリ(30 ミリ)秒以内での最適解との誤差が 3% 以内の解の出現頻度を調べた。

GA のパラメータは、集団個体数を 100 とし、交叉率と突然変異率はそれぞれ 10% に設定した。ランダム生成と挿入順制御 NI 生成の混合では、両生成法による初期集団の 50% ずつを混ぜ合わせて用いた。また、挿入順制御 NI 生成の閾値 w には 4 段階の倍率(0.5, 1.0, 1.5, 制限なし)を用いた。これらのパラメータは幾つかのパラメータセットによる予備実験の結果に基づいて決定した。

表 1. 30ミリ秒以内に実行可能な世代数

#	手法	初期化	突然変異	世代数
1	2opt型	ランダムNI	2opt型	24
2	ブロック型	ランダム + 挿入順制御NI	ブロック型	20

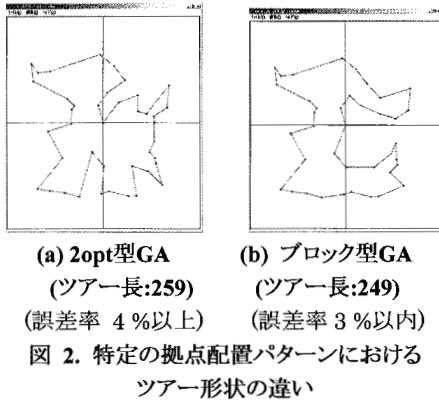
表 2. 誤差率3%以内の解の割合

#	手法	最適解	誤差率3%以内
1	2opt型GA	84.45%	99.885%
2	ブロック型GA	83.75%	99.785%
3	多段知能型GA	92.05%	100.0%

3.2. 実験結果

表 1 に 30 ミリ秒以内で計算可能な各 GA 方式の世代数を、表 2 に各 GA 方式における最適解の獲得率、専門家レベルの誤差率 3% 以内の解の獲得率を

示す。これを見ると、40都市TSPにおいて30ミリ秒以内に誤差率3%以内の解を100%獲得できたのは多段知能型GAだけである。これにより提案手法多段知能型GAの有効性が示された。



3.3. 評価

(1) ブロック型GAの効果:

2opt型GAによる実行結果から誤差率3%以上の解を解析したところ、図2(a)のようなギアホイール型のツアーフォームをした解が多数見られた。人間の専門家は大抵、図2(b)のような、より直線状のツアーフォームを生成する。もし専門家が図2(a)のような非効率的なツアーフォームを見つければ、彼らはそのシステムを信頼できないものとして使うことをやめるだろう。

ブロック型GAを使った場合は、そのような巡回拠点配置パターンにおいても図2(b)のような解を得ることができるであろう。なぜなら、このような局所的な不効率なルートはブロック型突然変異により改善される可能性が高いからである。事実このような形状のツアーフォームはブロック型GAによる結果では見られなかった。

(2) 多段知能型GA(MIGA)の効果:

実験の結果によると、2opt型GAの場合、20000テストケースの内43ケースで解の誤差率が3%以上であった。ブロック型GAの場合は、23ケースで解の誤差率が3%以上であった。しかしながら、多段知能型GAでは20000テストケースの全てで誤差率が3%以内であった。これは、多段知能型GAが2opt型GAとブロック型GAというタイプの違う、相補的特性を持つたGAの良い方の解を採用することにより、幅広い巡回拠点配置パターン

に対応できるためである。これにより、技術目標であった対話的応答性(各ルート数10ミリ秒以内、千ルートで数10秒)と専門家レベルの最適度(誤差率3%以内)を実現できた。

4. おわりに

本研究では、様々な巡回拠点配置パターンで専門家レベルの最適度と対話的応答性を実現するため、特性の違う2つのGA、2opt型GAとブロック型GAを組み合わせて用いる多段知能型GA(MIGA)を提案した。

2opt型GAは迅速に収束することにより、短時間で高い最適度の解を得ることができたが、ある特定の巡回拠点配置パターンでは、専門家レベルの最適度を保証できなかつた。しかし、ブロック型GAにより計算コストは多少増えたが2opt型GAの弱点パターンを克服することができた。この2つを組みあせて用いる多段知能型GAにより、大規模な配送ネットワークの対話的シミュレーションに必要な最適度と応答性でTSPを解くことができる事が示された。

<参考文献>

- [1] 山本、久保：巡回セールスマントラック問題への招待、朝倉書店(1997).
- [2] Grötschel, M.; and Holland, O., "Solution of large-scale symmetric traveling salesman problems", Mathematical Programming, Vol.51, pp.141-202, 1991.
- [3] Arora, S., "Polynomial Time Approximation Schemes for Euclidean TSP and Other Geometric Problems", Journal of the ACM, Vol. 45, No.5, pp.753-782, 1998.
- [4] 茨城俊秀. 離散最適化とアルゴリズム, 岩波書店(1993)
- [5] Hooker, J.H.; and Natraj, N.R. 1995. Solving a General Routing and Scheduling Problem by Chain Decomposition and Tabu Search, Transportation Science, Vol.29, No.1, pp.30-44.
- [6] S.Lin, and B.W.Kernighan, An effective heuristic algorithm for the traveling salesman problem, Operations Research, Vol. 21, No.2, Feb.1972, pp.498-516.
- [7] Kubota S.; Onoyama T.; Onayagi K. and Tsuruta S., "Traveling Salesman Problem Solving Method fit for Interactive Repetitive Simulation of Large-scale Distribution Network", Proc. IEEE SMC'99, pp. 533-538, 1999.
- [8] L.Davis. editor. Handbook of Genetic Algorithms. Van Nostrand Reinhold, NY, 1991.