

輸送問題と遺伝的アルゴリズムによる輸送コストマネジメント手法

安 高 真一郎*

A Transportation Cost Management Technique using Transportation Problem with Genetic Algorithm

Shinichiro Ataka *

Abstract

Logistics network design is one of the most important phases in supply chain management (SCM). Transportation problem (TP) is a well-known basic network model that can be generally defined as a problem to minimize the total delivery cost. However, the concept of inventory is not included in a traditional TP model. Moreover, time concepts, such as carrying costs in a certain period, are not treated. These restrictions on this model profoundly affect the use of the TP model in the real world. In this paper, we formulate a Progressive Flexible Logistics Network Model (PFLN). In this model, 1 year is divided into several terms and the annual demands of delivery centers are satisfied for each term. To solve the problem, we applied an effective genetic algorithm (GA) method called the Boltzmann random key-based GA (Brk-GA).

キーワード

輸送問題、遺伝的アルゴリズム、在庫、コストマネジメント

Keywords

Transportation Problem, Genetic Algorithm, Inventory, Cost Management

1. はじめに

近年、生産及び物流情報システムにおけるサプライチェーンマネジメント (SCM : Supply Chain Management) の役割は、情報技術の進展とともに重要性を増している [1] [2]。消費者のニーズの多様化とともに少品種多量生産から多品種少量生産に移行しつつあり、また情報技術を駆使することにより生産・流通過程での無駄を極力削減し

*あたか しんいちろう：大阪国際大学ビジネス学部講師 (2010.12.13受理)

企業競争力を高める努力が日夜行われている。物流分野ではジャストインタイム配送や小口多頻度輸送が課題であるが、交通網を用いる物流ではロボット等による高度な自動化は難しく、運転手等人手が多く介在する物流ネットワークでの最適化を図る必要がある[3]。これに関して、オペレーションズ・リサーチの分野で一般的に用いられる輸送問題（TP：Transportation Problem）は、Hitchcock らによって定式化された。その目的は、複数の供給地から複数の需要地へ、各需要が満たされる上での総配送コストの最小化である。しかしながら、TP を実世界へ適用するには、ネットワークモデルを多段階に拡張、あるいは更なる制約条件の付加等が必要となってくる。これまでも、従来の TP を改良した、2段階輸送問題（two-stage Transportation Problem）や、固定費輸送問題（Fixed Charge Transportation）、排他的制約を伴う配送問題（escTP：Transportation Problem with exclusionary side constraints）といったモデルが提案されているが、現実モデルと比較した場合、考慮されている事象はわずかなものとなっている[4-8]。例えば、在庫の概念および時間の概念は、従来の TP モデルに含まれていない。不良在庫及びその費用の削減は、ロジスティクスや経営・経済の分野で注目されている問題であり、不足を起こさず可能な限り少ない在庫量を維持する方法が研究され続けている。また、在庫の問題を取り扱う場合、同時に考慮する必要があるのが時間の概念である。ここでの時間とは、保管期間や納期等を考慮する上で必要な時間的要素を指す。他にも、多段階化したモデルにおいて、全てのノードが接続されているような、フレキシブルな配送経路を持つネットワークモデルや、多品種の生産状況下への対応、さらには今日のように短い製品ライフサイクルを考慮したモデルが昨今の研究課題となっている。

そこで本研究では、近年のロジスティクスの課題を反映した、発展型フレキシブル・ロジスティクスネットワークモデル（PFLN：Progressive Flexible Logistics Network Model）を提案し、物流において考慮すべき主要コスト最小化を行う。最適化手法には、問題の構造変化に柔軟に対応でき、比較的短時間に良質の解が得られる遺伝的アルゴリズム（GA：Genetic Algorithm）を採用する。

2. 提案モデル

輸送問題（TP：Transportation Problem）は、複数の供給地から複数の需要地へ、各需要が満たされる上での総配送コストを最小化する解を見つける問題であり、数理最適化法の応用分野として広く研究が行われてきた。しかし輸送の現実的な制約を考慮すると、厳密最適解は計算困難となる場合が多く、近似解やヒューリスティクスによる手法に加え、近年では生物の進化を模倣した探索手法である遺伝的アルゴリズム（GA：Genetic Algorithm）や、シミュレーテッド・アニーリング法（SA：Simulated Annealing）、タブー探索法（TS：Tabu Search）などのメタ戦略による最適化手法の研究が行われている[9][10]。

これまでに提案された TP の中で、図1のような今日の配送経路をより多く考慮したモデルとして、フレキシブル・ロジスティクスネットワークモデル（FLN：Flexible Logistics Network Model）がある[11][12]。この FLN では、ネットワーク上に存在す

る各施設が相互に結合されているという特徴を持っており、製品をメーカーから顧客へ直接輸送する事象も再現されている。しかしながら、一般的な TP と同様、在庫や時間に関する概念は含まれていない。ロジスティクスの改善は、多くの企業が目標としており、その中で大きな問題であるのが在庫管理 (inventory control) である。在庫を抱えることはコスト要因となるため、在庫管理ではできるだけ在庫を少なく抑えることが目標になる。しかしながら、在庫が不足するとサービスレベルが下がる可能性があるため、適切な在庫を維持することに伴う在庫コストと、サービスレベルをうまくバランスさせる必要がある。つまり、機会損失を最少に、かつ不良在庫を削減し、部品や製品の在庫量を適正に維持管理することは業績を左右する重要課題なのである。




図 1. 配送経路の例

本論文で提案する発展型フレキシブル・ロジスティクスネットワークモデル (PFLN: Progressive Flexible Logistics Network Model) は、従来の FLN に在庫の概念を付加し、工場で製造される製品は多種として拡張させたモデルといえる。モデル作成にあたり、在庫の概念を考慮する上で必要となる期間の概念についても考慮した。通常、製品または部品等の発注は、規定の在庫量を下回った場合(定量的)、または定期的に行われる。ここでは、期末に在庫維持費を計算する、時期発注量を決定するモデルであるため定期的な発注方式を考慮しモデル化を行った。具体的には、1年間を4期に分け、各期の総配送コスト、及び在庫維持費の最小化を目的にしている。

- A 1. ネットワーク上の各施設 (i, j, k) の最大許容量は既知とする。
- A 2. 顧客 1 の要求量は既知である。
- A 3. 各施設の最適配置場所については (i, j, k) 考慮しない。
- A 4. 各経路の輸送コスト $(c_{pij}^1, c_{pij}^2, \dots, c_{pij}^6)$ は既知である。
- A 5. 製品の製造時間および各経路の配送時間は考慮しない。
- A 6. 時間経過による価値の変動は考慮しない。
- A 7. 数値実験では、4回の輸送計画を行う。

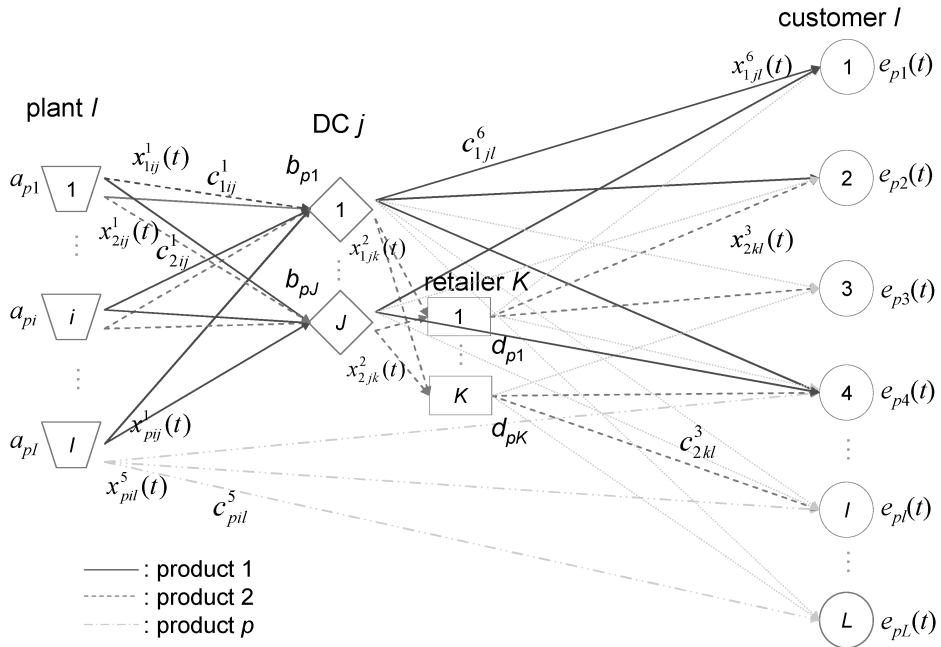


図 2. PFLN のイメージ

インデックス：

- i ：プラント ($i = 1, 2, \dots, I$)
- j ：DC ($j = 1, 2, \dots, J$)
- k ：リテーラー ($k = 1, 2, \dots, K$)
- l ：顧客 ($l = 1, 2, \dots, L$)
- p ：製品の種類

パラメータ

- a_{pi} ：製品 p におけるプラント i の許容量
- b_{pj} ：製品 p における DC j の許容量
- d_{pk} ：製品 p におけるリテーラー k の許容量
- $e_l(t)$ ：期間 t における製品 p に対する顧客 l の要求量
- c_{ij}^1 ：製品 p のプラント i から DC j までの輸送コスト
- c_{jk}^2 ：製品 p の DC j からリテーラー k までの輸送コスト
- c_{kl}^3 ：製品 p のリテーラー k から顧客 l までの輸送コスト
- c_{pij}^4 ：製品 p のプラント i からリテーラー k までの輸送コスト
- c_{pil}^5 ：製品 p のプラント i から顧客 l までの輸送コスト
- c_{pjl}^6 ：製品 p の DC j から顧客 l までの輸送コスト

c_{pi}^0 : 製品 p の製造費

c_{pj} : 製品 p における DC j の運営費

$q_{pi}(t)$: 期間 t におけるプラント i での製造量

決定変数

$x_{pij}^1(t)$: 期間 t におけるプラント i から DC j までの輸送量

$x_{pjik}^2(t)$: 期間 t における DC j からリテーラー k までの輸送量

$x_{pkl}^3(t)$: 期間 t におけるリテーラー k から顧客 l までの輸送量

$x_{pik}^4(t)$: 期間 t におけるプラント i からリテーラー k までの輸送量

$x_{pil}^5(t)$: 期間 t におけるプラント i から顧客 l までの輸送量

$x_{pjl}^6(t)$: 期間 t における DC j から顧客 l までの輸送量

$u_{pi}(t)$: 期間 t におけるプラント i の在庫量

$u_{pj}(t)$: 期間 t における DC j の在庫量

z_i : プラント i が稼動する場合は 1、それ以外は 0

なお、PFLN の数学モデルは以下のようになる。

$$\begin{aligned} \min \quad z = & \sum_{t=1}^T \sum_{p=1}^P \left(\sum_{i=1}^I \sum_{j=1}^J c_{pij}^1 x_{pij}^1(t) + \sum_{j=1}^J \sum_{k=1}^K c_{pjik}^2 x_{pjik}^2(t) + \sum_{k=1}^K \sum_{l=1}^L c_{pkl}^3 x_{pkl}^3(t) + \sum_{i=1}^I \sum_{k=1}^K c_{pik}^4 x_{pik}^4(t) \right. \\ & \left. + \sum_{i=1}^I \sum_{l=1}^L c_{pil}^5 x_{pil}^5(t) + \sum_{j=1}^J \sum_{l=1}^L c_{pjl}^6 x_{pjl}^6(t) + \sum_{j=1}^J c_{pj} u_{pj}(t) + \sum_{i=1}^I c_{pi}^0 z_i(t) \right) \end{aligned} \quad (1)$$

$$\text{s. t.} \quad u_{pi}(t) = u_{pi}(t-1) + q_{pi}(t) - \sum_{j=1}^J x_{pij}^1(t) - \sum_{k=1}^K x_{pik}^4(t) - \sum_{l=1}^L x_{pil}^5(t), \quad \forall t, i, p \quad (2)$$

$$u_{pj}(t) = u_{pj}(t-1) + \sum_{i=1}^I x_{pij}^1(t) - \sum_{k=1}^K x_{pjik}^2(t) - \sum_{l=1}^L x_{pjl}^6(t), \quad \forall t, p, j \quad (3)$$

$$u_{pi}(t-1) + q_{pi}(t) \leq a_{pi} z_i(t), \quad \forall t, p, i \quad (4)$$

$$u_{pj}(t-1) + \sum_{i=1}^I x_{pij}^1(t) \leq b_{pj}, \quad \forall t, p, j \quad (5)$$

$$\sum_{i=1}^I x_{pik}^4(t) + \sum_{j=1}^J x_{pjik}^2(t) \leq d_{pk}, \quad \forall t, k, p \quad (6)$$

$$\sum_{i=1}^I x_{pil}^5(t) + \sum_{j=1}^J x_{pjl}^6(t) + \sum_{k=1}^K x_{pkl}^3(t) \geq e_{pl}(t), \quad \forall t, l, p \quad (7)$$

$$x_{pij}^1, x_{pjik}^2, x_{pkl}^3, x_{pik}^4, x_{pil}^5, x_{pjl}^6 \geq 0, \quad \forall i, j, k, l, p \quad (8)$$

$$u_{pi}(t) \geq 0, \quad \forall p, i, t \quad (9)$$

$$u_{pj}(t) \geq 0, \forall p, j, t \quad (10)$$

$$z_i(t) = \{0, 1\}, \forall i \quad (11)$$

制約条件である式（２）と（３）は、期間 t におけるプラント i と DC j の在庫量をそれぞれ表す。式（４）～（７）は、各施設の最大許容量に関する制約条件である。前述のとおり、本モデルでは多期に渡る輸送プランを決定する。そのため、前期より繰り越されてきた在庫量も考慮しながら次期発注量を決定する。次期発注量の決定については次章で述べる。式（６）と（７）は、非負条件である。

３．PFLN の解法

３．１ ボルツマン・ランダムキー型遺伝的アルゴリズム（Brk-GA： Boltzmann random key-based GA）

ここでは、PFLN の解手法として、ボルツマン・ランダムキー型遺伝的アルゴリズム（Brk-GA： Boltzmann random key-based GA）を用いる [13]。GA については、高い計算負荷や局所解への早熟収束、交叉率・突然変異率といったパラメータ設定の複雑さなどの課題が存在し、これまでも多くの拡張型 GA が提案されてきた。従来の FLN においても、その提案と同時に GA による解法も提案されているが、FLN を解くことに特化した染色体表現であるため、TP に用いる GA としては汎用性の低いものとなっている。著者は、過去に一連の TP に対し効率的な Brk-GA を設計し、評価実験により有効性を確認している。本研究では PFLN モデルに、Brk-GA を適用し、同時に複雑な配送形態を容易に染色体化する手法についても提案を行う。

一般的に、問題が複雑になるにつれ、厳密解法にて最適解を求めることは困難になり、また数あるソフトコンピューティング技法においても準最適解を瞬時に計算することは困難となる。さらに、ソフトコンピューティング技法においては、その頑健性と計算時間が議論の主題として取り上げられることが多い。この問題点は GA においても当てはまることであり、これまでも多くの文献でその問題解決が取り上げられてきた。しかしながら、そのほとんどの文献は、新たな染色体表現や交叉法、突然変異法を提案するものであり、探索空間をどれだけカバーできているかや、局所解への早熟収束という問題点については議論されていない。Brk-GA は、ランダムキー型の染色体表現を用い、局所探索法、及び新しい選択メカニズムとしてボルツマン分布に基づいた選択手法を含んでいる。この選択手法は、ボルツマン・ルーレット戦略と呼ばれ、GA において一般的であるルーレット戦略を改良したものである。従来のルーレット戦略は、局所解に陥り易いや、例え最適解が発見されたとしても、確率的に次世代集団を生成するため、誤って淘汰されることも問題視されていた。これに対し、ボルツマン・ルーレット戦略は、進化の初期段階では選択基準が低く、進化するにつれ選択基準が厳しくなるといふ、集団の多様性を考慮した探索が可能であり、探索時に局所解へ早熟収束することを極力避けることが可能である。さらに、Brk-GA は、これまでの研究で多く見受けられた、交叉や突然変異の改良には重きを置い

ておらずシンプルな構造を持っている。

3.2 染色体表現

図3は、ランダムキー型の染色体表現の例である。この例では、一般的なTPと同じく、ネットワーク上にプラントとDCのみが存在するモデルを取り上げている。染色体中の各遺伝子は、0から1の間で発生させた乱数で表される。また、染色体の長さは、プラントとDCの総数に等しい。遺伝子座は、各施設の番号に対応し、各遺伝子の値はその優先順位を表す。




図 3. ランダムキー型染色体表現の例

デコード処理では、最大の値を持つ遺伝子を優先順位が最も高いものとし、コスト行列を参考に、最小コストの経路を選択する。まず、染色体から DC 1 が最も高い優先順位値 7 を持ち、コスト行列から最小コスト 11 の経路がプラント 1 - DC 1 間にあることが分かる。ここで、プラント 1 と DC 1 を結ぶアークがツリーに加えられ、それぞれのキャパシティが更新される。続いて、次に高い優先順位を持つ DC 4 が選択され、DC 4 とプラント 3 の間でアークを加えた後、それらのキャパシティは更新される。以上に説明されるように、全ての DC 要求が満足されるまで、この過程を繰り返す。

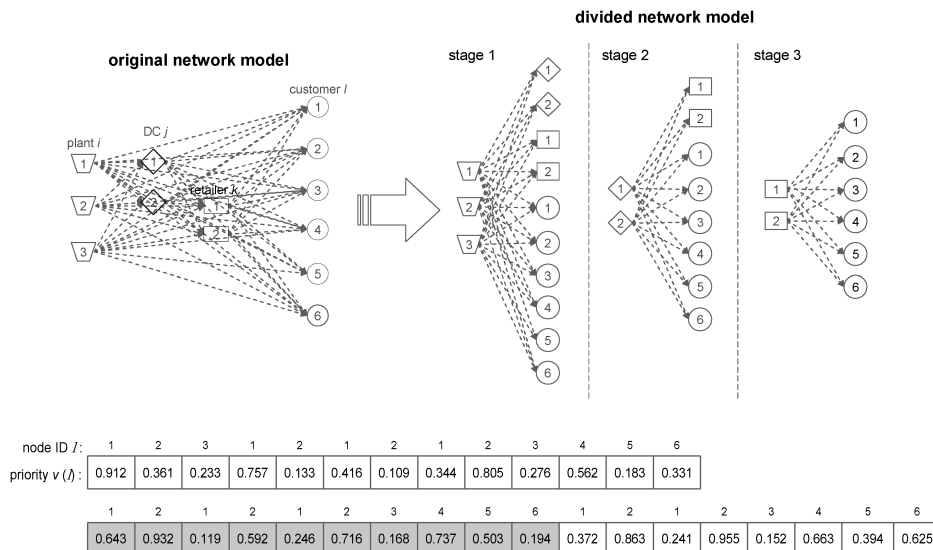


図 4. ネットワークモデルの分割

ただし、今回提案する PFLN は、一般的な TP とは大きく異なり、複雑な配送形態を持つため、ランダムキー型染色体表現をそのまま適用することができない。そこで、ネットワークモデルを 3つの段階に分割する手法を適用する。染色体は、各段階に対応したパートの組み合わせとなり、本手法を用いることで、複雑なネットワークモデルも簡略化して解くことが可能となる。図 4 に分割のイメージと、それに対応する染色体表現の例を示す。

3.3 遺伝オペレータ

Brk-GA では、ランダムキー型の染色体表現を用いるため、交叉にはシンプルは 1 点交叉を用いる。シンプルな 1 点交叉を用いることで計算時間の短縮を狙う。また、各段階に対し交換突然変異を用いる。2つの遺伝子をランダムに選択し、そのポジションを交換する。適合度の計算には、目的関数値を用いる。

実数 GA では、交叉・突然変異を行った後、染色体（解）及び集団に急激な変化が現れることがある。そのため、交叉率と突然変異率は慎重に設定する必要がある。大きな交差率と突然変異率を設定することは、ある点に収束しようとしている集団に、さらに探索を促すことにつながる。このことは、計算時間を延ばすことと同じ意味を持っており、急激な変化や進化を行わせることは、急速に収束を促すことにもなり、局所解へ陥る確率が高くなる。上記は、探索スペースを狭めてしまい、十分な探索が行われないことを意味する。

従来のルーレット戦略では、同じ固体が次世代候補に選ばれることがり、その反面、良い固体が選ばれない、または選ばれたとしても次の世代で選択されない可能性が発生してしまう。また、非常に評価の高い個体が選択された場合は、局所解に収束する可能性も考えられる。上記を解決するため、Brk-GA では、ボルツマン分布を利用したボルツマン・

ルーレット戦略が組みこまれている。式12は、一般的なボルツマン分布の数学モデルである。 b_T は温度を、 F_A は現世代における評価値の合計をそれぞれ表す。進化の初期段階では、式9により集団の多様性を保つため低い評価基準が適用される。その後、進化が進むにつれ、評価基準は厳しくなっていく。本研究では、数値実験において温度 b_T の値は予備実験を基に設定している。次世代に残す固体は、式9で得られた評価基準を基にルーレット選択により選択される。ボルツマン・ルーレット選択のプロシージャを図5に、Brk-GAの全体のプロシージャを図7に示す。ここで、 $P(t)$ と $C(t)$ は現世代 t における親と子をそれぞれ表し、 b_{TM} は最小温度を表す。本研究では、 b_{TM} を1に設定している。また、 F_{SUM} は評価値の合計を表し、 F_{AVG} は平均評価値を表している。

$$eval(v_k) = \frac{e^{\frac{F_k}{b_T}}}{\frac{1}{popSize} \sum_{n=1}^{popSize} e^{\frac{F_n}{b_T}}} \quad (12)$$

<pre> procedure: Boltzmann scaling selection input: population, $P(t-1)$, $C(t-1)$, $popSize$ output: population, $P(t)$, $C(t)$ begin step1: Check the current Boltzmann temperature if ($b_T < b_{TM}$) then $b_T \leftarrow b_{TM}$ step2: Calculate the average fitness F_{AVG} for the population using e for ($k=1$ to $popSize$) $F_{SUM} += \exp(eval(v_k) / b_T)$; $F_{AVG} \leftarrow F_{SUM} / popSize$ step3: calculate the new fitness for ($k=1$ to $popSize$) $eval(v_k) \leftarrow \exp(eval(v_k) / b_T) / F_{AVG}$; </pre>	<pre> step4: Calculate the total fitness F for the population $F_T = \sum_{k=1}^{popSize} eval(v_k)$; step5: Calculate selection probability $p_k = eval(v_k) / F$, for each v_k // The following step 6 & step7 are general roulette wheel selection. step6: Calculate cumulative probability step7: Generate a random number r from the range[0, 1] to select the individuals. step8: Update the current Boltzmann temperature $b_T \leftarrow b_T - b_{TC}$ end </pre>
--	--

図 5. ボルツマン・ルーレット戦略

```

procedure: Brk-GA
input: problem data, GA parameters ( $popSize$ ,  $maxGen$ ,  $P_C$ ,  $P_M$ )
output: the best solution
begin
     $t \leftarrow 0$ ;
    initialize  $P(t)$  by random key-based encoding routine;
    evaluate  $P(t)$  by random key-based decoding routine;
    while (not terminating condition) do
        create  $C(t)$  from  $P(t)$  by one-cut crossover;
        create  $C(t)$  from  $P(t)$  by insertion mutation routine;
        climb  $C(t)$  by local search routine;
        evaluate  $P(t)$  by random key-based decoding routine;
        select  $P(t+1)$  from  $P(t)$  and  $C(t)$  by Boltzmann roulette selection
         $t \leftarrow t+1$ ;
    end
output: the best solution
end

```

図 6. Brk-GA のプロシージャ

4. 数値実験

ここでは、以下の 5 手法による比較実験を行う：

1. スパニングツリー型 GA (st-GA : spanning tree-based GA)
2. 優先順位型 GA (priGA : priority-based GA)
3. ハイブリッド優先順位型 (h-priGA : hybrid priority-based GA)
4. ボルツマン・ランダムキー型 (Brk-GA : Boltzmann random key-based GA)
5. ハイブリッド・ボルツマン・ランダムキー型 GA (h-BrkGA : hybrid Boltzmann random key-based GA)

下記に、各 GA の設定を示す。

表 1. 比較に用いる GA とその設定

GA	染色体表現	交叉	突然変異	flc	選択
st-GA	Prufer 数ベース	一点交差	交換	-	ルーレット戦略
priGA	優先順位ベース	WMX	交換	-	ルーレット戦略
h-priGA	優先順位ベース	WMX	交換	on	ルーレット戦略
Brk-GA	ランダムキーベース	一点交差	交換	-	ボルツマン・ルーレット戦略
h-BrkGA	ランダムキーベース	一点交差	交換	on	ボルツマン・ルーレット戦略

ここで、Weight Mapping Crossover (WMX) は、priGA に適した交叉法として提案された手法である。この手法は、一点交叉の拡張型として見ることができる。また、ファジロジックコントローラ (flc : fuzzy logic controller) は、交叉率と突然変異率をオートチューニング手法である。本手法を用いる場合、進化の速度は劇的に向上するが、局所解へ早熟収束する可能性が考えられるため、今回は多様性を考慮する Brk-GA との比較を行う。本研究で提案する TP モデルは、 t 期末に DC の次期発注量を決定するモデルとなっている。次期の需要予測値は指数平滑法を応用した以下の式で決定され、この予測値から現在の在庫量を差し引いた量が次期発注量となる。

$$\begin{aligned} \text{予測値} &= \alpha \times \text{前回実績値} + (1 - \alpha) \times \text{前回予測値} \\ y_{ejk}^F(t) &= \alpha y_{ejk}(t-1) + (1 - \alpha) y_{ejk}^F(t-1) \end{aligned} \quad (13)$$

ここで、係数 α (平滑定数) は、 $0 < \alpha < 1$ の範囲で設定される。 α が 1 に近いほど直前値を重視し、0 に近いほど過去の経過を重視することになる。表 2 に、実験に用いたテストデータを示す。数値実験を行うには、計算スタート時 ($t = 0$) の予測値が必要となるため、ここでは 100-150 の間でランダムに発生させた。また、DC の初期在庫量は、それぞれ 10-20 間でランダムに作成した。

表 2. テストデータ

Problem No.	No. of plants(i)	No. of DCs(j)	No. of retailers(k)	No. of customers(l)	Population size	Crossover rate	Mutation rate
1	2	5	8	20	100	0.2	0.1
2	3	7	12	30	100	0.2	0.1
3	5	3	12	45	100	0.3	0.1
4	6	8	20	80	100	0.3	0.1

表 3 に、各アルゴリズムを 30 回ずつ実行した時の最良解、解の平均、標準偏差 (SD)、そして平均計算時間 (ACT) を示す。また、最良解の下に示されているのは、各期での配送費用 (解) である。図 7 は、問題 4 を $t = 1$ として実行した場合の進化のグラフである。ここでは、500 世代以降、各 GA の進化は見られなかった。

表 3. 実験結果

Problem No.	st-GA				priGA			
	Best	AVG	SD	ACT (s)	Best	AVG	SD	ACT (s)
1	55318.12	56763.05	778.97	14.45	55188.03	55888.55	576.54	15.25
2	59601.00	60743.65	674.84	24.79	59280.22	60621.00	762.91	24.47
3	82874.00	85566.35	1108.78	34.66	82331.00	83917.25	1315.4	31.01
4	87038.01	88138.30	765.76	34.84	86915.00	88369.35	755.95	32.61
Problem No.	h-priGA				h-BrkGA			
	Best	AVG	SD	ACT (s)	Best	AVG	SD	ACT (s)
1	55045.40	56191.05	573.02	10.80	54929.00	56349.15	756.64	3.83
2	59065.03	60600.90	582.70	16.04	58887.80	60229.00	696.65	5.00
3	81726.06	84165.50	991.04	19.89	79875.00	81827.60	1044.15	6.17
4	85921.00	87878.05	1000.40	20.42	82391.20	85845.55	1476.72	7.17
Problem No.	Brk-GA							
	Best	AVG	SD	ACT (s)				
1	54909.22	55003.15	294.20	3.73				
2	58263.17	59978.90	570.62	4.95				
3	79761.87	80949.85	669.86	6.13				
4	81544.05	83480.15	948.74	6.91				




図 7. 各 GA における進化の様子

結果から、全ての問題に対し Brk-GA が最良解 (Best) を得ていることがわかる。さらに、解の平均 (AVG) と平均計算時間 (ACT) においても最良であることが確認された。これは、ランダムキーベースの染色体表現によりシンプルな交叉法を適用できたことが作用していると考えられる。また、ローカルサーチを含んでいながら、短い計算時間で解を求めることが可能であった。問題 4 では、stGA と priGA が低い標準偏差 (SD) 値を示した。しかしながら、AVG を Brk-GA と比較した場合、探索がよい解を得る前に収束したことを確認することができる。また、FLC を導入することで、計算時間が短縮されることが確認できる。しかし、priGA と h-priGA、Brk-GA と h-BrkGA をそれぞれ比べた場合、SD 値が劣化していることが見て取れる。これは、急速な進化のために、毎回大きく異なる解を算出してしまっていることを表している。得られた解の質から見て、Brk-GA は効果的に計算時間を削減していると言える。Brk-GA と比較手法の中で一番古い TP 用 GA である st-GA を比較すれば、最良解は 6.3% 改善され、計算時間は 66.1% 改善されている。

5. おわりに

本研究では、より現実的な TP モデルとして PFLN モデルを提案した。また、特別な染色体表現を必要としないネットワーク区分法の提案も行った。数値実験では、5 つの GA (st-GA, priGA, h-priGA, Brk-GA, h-BrkGA) を用い比較実験を行った。上記の 5 手法には、ネットワーク区分法が適用されており、全ての GA で計算が可能だった。結果からは、Brk-GA が解の質、計算時間において、他の手法より優れていることが明らかとなった。Brk-GA と比較手法の中で一番古い st-GA を比較すれば、最良解は 6.3%、計算時間は 66.1% 改善されていることが確認された。GA に flc を組み込んだ場合、計算時間こそ劇的に改善されるが、これまでの実験結果では局所解へ早熟収束している可能性が感じられた。当実験結果では、Brk-GA が最良解において最もよい結果を示したが、flc を組み込んだ Brk-GA と比較を行うと、解の平均と標準偏差が悪化することが確認された。ソフトコンピューティング技法は、準最適解を早い段階で求めるという特徴を持つが、実行の度に解に大きなばらつきが生じることは、その頑健性、信頼性を疑いかねない。今回の実験では、Brk-GA が従来の TP 用 GA の中で有効な手法と結果付けられるが、より大きな問題への適用と実際のデータを用いたケーススタディが今後の課題である。

参考文献：

- [1]. K. Ertogal, S. D. Wu and L. I. Burke, "Coordination Production and Transportation Scheduling in the Supply Chain", Technical Report #98T-010, Department of Industrial & Mfg. Systems Engineering, Lehigh University, 1998.
- [2]. 谷口憲, 寺野隆雄, "進化論的計算手法によるサプライチェーンマネジメント支援に関する一考察", 電子情報通信学会技術研究報告[人工知能と知識処理], vol.100, no.89, AI2000-17, pp.57-61, 2000.
- [3]. 圓川隆夫, 伊藤謙治, 笠原鉄雄, 陳大, "欠品ゼロと在庫最小化を目指した多期間配送計画問題とその解法", 日本経営工学会論文誌, vol.46, no.5, pp.492-502, 1995.
- [4]. 江川隆章, 今野浩, "整数計画法を用いた凹型生産コスト付き輸送問題最適化", 日本オペレーションズ・リサーチ学会秋季研究発表会アブストラクト集, pp.68-69, 2004.

- [5]. 樋口幸夫, 片岡靖司, “次数制限付き輸送問題のリスト表現を用いた分枝限定法”, 日本オペレーションズ・リサーチ学会秋季研究発表会アブストラクト集, pp.216-217, 2006.
- [6]. J. Nakano, T. Tokuyama, “Efficient Algorithms for the Hitchcock Transportation Problem”, Proc. of The 44th Information Processing Society of Japan, pp.89-90 1992.
- [7]. 安高真一郎, 玄光男, “ハイブリッド型遺伝的アルゴリズムによる配送経路に制約を伴う多品種2段階配送計画モデルの解法”, 電気学会論文誌 C, vol.128, no.3 pp.456-461, 2008.
- [8]. 石渕久生, 田中英夫, “区間型の需要関数に基づく出荷計画問題に関する研究”, 日本経営工学会誌, vol.39, no.4, pp.262-269, 1988.
- [9]. Sadiq M. Sait and H. Youssef, “Iterative Computer Algorithms with Applications in Engineering”, Wiley-IEEE Computer Society, 2000.
- [10]. M. Yanagiura and T. Ibaraki, “Combination Optimization”, Asakura Publishing, 2001.
- [11]. L. Lin, M. Gen, and X.Wang, “A Hybrid Genetic Algorithm for Logistics Network Design with Flexible Multistage Model”, *International Journal of Information Systems for Logistics and Management*, vol. 3 (1), pp.1-12, 2007.
- [12]. L. Lin, M. Gen, and X. Wang, “Integrated Multistage Logistics Network Design by Using Hybrid Evolutionary Algorithm”, *Computers & Industrial Engineering*, vol.56(3), pp.854-873, 2009.
- [13]. S. Ataka, B. Kim, M. Gen, Optimal Design of Two-stage Logistics Network Considered Inventory by Boltzmann Random Key-based GA, IEEJ Transactions on Electrical and Electronic Engineering, 5 : 195-202, 2010.
- [14]. M. Gen and R. W. Cheng and L. Lin, “*Network Models and Optimization: Multiobjective Genetic Algorithm Approach*”, Springer, 2008.