

変動する環境下での1機械スケジューリング問題に対する 遺伝アルゴリズムの適用について

*京都大学 加藤 真治 KATOH Shinji
京都大学 柳浦 睦憲 YAGIURA Mutsunori
京都大学 茨木 俊秀 IBARAKI Toshihide

1 はじめに

遺伝アルゴリズム (genetic algorithm, GA) の特徴の一つは、曖昧で、しかも環境が変動するような複雑な問題にも対応できる柔軟性にある。この点を確認するため、組合せ最適化問題において、問題例を定めるパラメータの確率的挙動は知られているものの、具体的な値は分からず、しかもそれが徐々に変動するという設定で、問題例のデータが確定する度に即座に解を出力しなければならない状況に適用した。遺伝アルゴリズムでは解の候補をいくつか用意しているので、解が必要になる度にその中から最良の解を出力することで、このような状況に対応できることが期待される。

一方、このような状況では、その都度、欲張り法のような簡単な近似解法 [1] で解を求め利用するという方法もとること出来る。それで、ここでは、組合せ最適化問題の具体例として、各仕事の処理時間が、毎朝スケジュールをする時点になるまで確定しないようなスケジューリング問題を考え、両アプローチを比較した。

2 1機械スケジューリング問題

与えられた n 個の仕事 $\{1, \dots, n\}$ を1台の機械で処理する。各仕事 i に対し、処理時間 p_i (processing time) と重み w_i (weight) が与えられ、また、各仕事のペア (i, j) に対し、段取り替え時間 e_{ij} が与えられる。機械は一度に1つの仕事しか処理できず、また、ある仕事が始めると、それが完了するまで処理の中断は許されない。処理間の無駄時間はないものとする。従って、スケジュールは、 n 個の仕事の順序 $\sigma = (\sigma(1), \sigma(2), \dots, \sigma(n))$ で決定される。スケジュール σ が決まると、各仕事 $\sigma(i)$ の完了時刻 C_i (completion time) は、

$$C_i = \sum_{k=1}^{i-1} (p_{\sigma(k)} + e_{\sigma(k)\sigma(k+1)}) + p_{\sigma(i)}$$

と定まる。重み付き滞留時間 (weighted flow time)

$$f(\sigma) = \sum_{i=1}^n w_i C_i \quad (2.1)$$

を最小にする順序を最適スケジュールとする。

本研究では、上述の1機械スケジューリング問題の問題例が、毎日定期的に生成され、毎日ある定まった時刻までにスケジュールを決定する必要がある状況を考える。各仕事の処理時間 p_i は、その時刻の直前まで未知とする。但し、各仕事の処理時間には過去のデータがあり、その平均と分散は既知とするが、処理時間の平均値は、日々徐々に変化する。簡単のため、問題例の他のパラメータである重み w_i と段取り替え時間 e_{ij} は、あらかじめ確定しているとする。このような状況で数ヶ月間、日々のスケジュールを決定し続けることが要求されており、毎日のスケジュールの決定に時間をかけたのでは意味がない。

3 遺伝アルゴリズム

各仕事の処理時間が、スケジュール決定の直前まで確定していないので、過去 D 日分 (D はアルゴリズムのパラメータ) のデータを基に予測した処理時間の下で GA を r_1 世代反復することによって、 P 個の候補解をあらかじめ用意しておく。毎日、各仕事の処理時間が定まり、目的関数が確定すると、用意してある P 個の候補解の中から、その日のデータに対し目的関数値を最小にするものを選んで、その日のスケジュールとする。また、各仕事の処理時間の平均値は徐々に変動していくので、初めに用意した P 個の候補解をそのまま長期間用いたのでは、得られる解の精度は悪化していく。そこで、 I 日経過するごとに、その都度 GA をさらに r_2 世代反復し (I, r_2 はアルゴリズムのパラメータ)、候補解を更新することにより、環境の変化に追従させる。なお、解の精度を上げるため、

以下のように GA に局所探索法 (local search) を組み合わせて利用する [3].

アルゴリズム (genetic local search)

Step 1 (初期化): 初期解を P 個生成.

Step 2 (増殖): 以下のステップを繰り返し, 新たな解を Q 個生成.

2-a (交叉): P 個の候補解の中から 2 つを選び, 交叉させ, 解を 1 つ生成.

2-b (改良): 各仕事の処理時間の予測値を決定し, それに基づく目的関数の下で局所探索.

Step 3 (淘汰): ステップ 2 で得られた Q 個の解と元から保持している P 個の解を合わせたものの中から, P 個を残す.

Step 4 (反復): ステップ 2 と 3 を 1 世代とし, このプロセスを r 世代繰り返す.

初期解は, 全てランダムに生成する. 交叉法には, order crossover を一様交叉として用いる [4]. 局所探索, および, 淘汰を行う際に必要となる解の評価には, 過去 D 日分のデータから得られる処理時間の平均と分散に基づく正規分布に従って具体的な処理時間を生成し, この処理時間を用いて (2.1) によって評価するのである. 局所探索法には, 交換 (swap) 近傍を用いる. 淘汰は, まず重複する解を除き, 残ったものの中で評価値の良いものから順に P 個を残す方法を採用している.

4 計算実験

[2] に述べた方法に従ってランダムに生成した問題例に対し, 上述の GA と欲張り法を適用し比較した. 図 1 は, 実験中に得られた最良の解 (処理時間 p_i が確定したデータに対して局所探索法を十分時間をかけて行うなどの方法により得られた解を含む) の値からの誤差の 1 週間毎の平均値を示している. 図中, greedy は欲張り法, GA- i は GA においてパラメータ r_2 を i とおいたものである. GA のその他のパラメータは, $P = 100, Q = 50, r_1 = 100, D = 28, I = 7$ とした. 欲張り法と GA の詳細については, [2] を参照のこと.

グラフより, 簡単な欲張り法によってその都度解を生成する方法では, 誤差が 4 ~ 6% 程度であるのに対し, GA では, 保持する候補解の更新を行わない $r_2 = 0$ の場合を除いて, 解の誤差が常に 2% 以下に収まっており, 平均的にみて, かなり精度の高い解が得られていることが確認できる.




図 1: 1 週間毎の平均誤差 (%) の変動

5 まとめ

1 機械スケジューリング問題において, 処理時間 p_i が確率的に変動するという設定で, GA の持つ候補解の中からその都度最良の解を出力する方法が有効であることを確かめた. 今後, 時間帯によって交通渋滞の状況が変動する中, 宅配などの最短の巡回路を見つける問題に対しても同様の考察を行う予定である.

謝 辞

数多くの助言を与えて頂いた永持仁助教授, 並びに茨木智助手をはじめお世話になった茨木研究室の諸先輩方に厚くお礼申し上げます.

参考文献

- [1] 茨木, “スケジューリング問題と計算の複雑さ,” オペレーションズ・リサーチ, **10**, 541-546, 1994.
- [2] 加藤, “変動する環境下での 1 機械スケジューリング問題に対する遺伝アルゴリズムの適用について,” 京都大学工学部数理工学科卒業論文, 1995.
- [3] 久保, “メタヒューリスティックス,” 離散構造とアルゴリズム IV (6 章), 近代科学社, 1995 出版予定.
- [4] 柳浦, 茨木, “順序問題における遺伝的交叉法に対する一考察,” 電気学会論文誌, **114-C(6)**, 713-720, 1994.