

O abordare evolutivă a planificării proceselor

Ionuț Balan, Sorin Vlad

Abstract—This paper aims to emphasize the results obtained by using genetic algorithms in scheduling comparatively with other classical methods used in the same purpose. A scheduling problem is defined by a set of jobs and a set of resources. The jobs are constrained by the relation of precedence forcing some of the jobs to wait until the other jobs are completed. The goal is to find a schedule minimizing the overall completion time. As case study is considered the problem of scheduling n jobs on m machines, each job having a certain running time on each machine.

Index Terms—genetic , neh, offspring, flow shop, random

I. INTRODUCERE

Datorită numeroaselor aplicații din industrie și economie, problema flow-shop a fost studiată de către numeroși cercetători care au impus diverse limitări problemei, au definit diverse funcții obiectiv și au implementat diverse tehnici de optimizare.

La baza unei probleme flow-shop clasice stau două elemente: M mașini (în general, sau calculatoare în particular) și N operații de prelucrat de către aceste mașini. Secvența de procese, ce compune fiecare din cele N operații, are aceeași ordine de execuție pe fiecare dintre cele M mașini. Fiecare operație poate fi executată pe o singură mașină la un moment dat și fiecare mașină poate executa doar o singură operație la un moment dat. Fiecare operație este prelucrată o singură dată pe o singură mașină. Problema principală constă din determinarea ordinii și a timpilor de execuție a operațiunilor astfel încât timpul total de execuție al acestora să fie minim. Se urmărește planificarea proceselor fiecărei operații pe fiecare dintre cele M mașini astfel încât să se evite cât mai mult posibil apariția unor procese care sunt nevoite să aștepte execuția pe o anumită mașină.

Dacă numărul de mașini este $M=2$ atunci problema se poate rezolva cu ajutorul algoritmului lui Johnson. Dacă numărul de mașini este $M=3$ atunci problema este NP complexă și pune serioase probleme de calcul. În acest caz există $(n!)^m$ alternative de secvențiere a operațiilor.

Regula lui Johnson este cea mai cunoscută regulă optimă aplicabilă unei clase largi de probleme flow-shop. Regula lui

Johnson afirmă că operația i precede operația j într-o secvență optimă dacă $\min\{t_{i1}, t_{j2}\} \leq \min\{t_{i2}, t_{j1}\}$. Cu ajutorul regulii lui Johnson problema flow-shop pentru $M=2$ poate fi rezolvată astfel:

Pasul 1: Determină $\min_i \{t_{i1}, t_{i2}\}$

Pasul 2: Dacă operația cu timpul minim de prelucrare necesită mașina 1, plasează operația asociată pe prima poziție disponibilă din secvența de execuție. Salt la pasul 3.

Pasul 22: Dacă operația cu timpul minim de prelucrare necesită mașina 2, plasează operația asociată pe prima poziție disponibilă din secvența de execuție. Salt la pasul 3.

Pasul 3: Se șterge operația și se revine la pasul 1 până când toate pozițiile din secvența de execuție sunt completate.

II. ALGORITMUL NEH

Nawaz a propus algoritmul NEH, ideea centrală a acestuia fiind aceea că unei operații cu un timp total de execuție mai mare pe toate mașinile trebuie să i se acorde o mai mare prioritate decât unei operații cu un timp total de execuție mai mic. În consecință, operațiile se vor aranja în ordinea descrescătoare a timpului total de execuție calculat, de

exemplu pentru operația j ca fiind $\sum_{i=1}^m t_{ij}$.

Algoritmul NEH presupune apoi secvențierea parțială a operațiilor bazată pe prioritățile stabilite anterior. O secvență va fi construită prin introducerea, la un moment dat, a unei operații neplanificate în schema de planificare parțială. Dacă în schema parțială sunt k operații, în momentul introducerii fiecărei operații se alege cea mai bună secvență parțială dintre cele $k+1$ secvențe parțiale posibile. Noua operație poate fi plasată în una dintre cele $k+1$ poziții din secvența parțială. După alegerea celei mai bune poziții din secvență pentru operația respectivă, ținând cont și de durata de execuție obținută, această porțiune din secvența parțială va rămâne fixă și se va insera o nouă operație. Locul de plasare a operației în secvență se stabilește în funcție de timpii de prelucrare ai tuturor mașinilor, luați în ordine descrescătoare

Algoritmul NEH poate fi prezentat pe scurt astfel:

*) Se ordonează cele n operații în ordinea descrescătoare a sumei timpilor de execuție pe cele m mașini.

*) Se iau primele două operații și se ordonează astfel încât să se minimizeze timpul total de execuție. În această etapă se consideră că secvența este formată doar din cele două operații.

Ionuț Bălan este preparator în cadrul Catedra de Informatică a Facultății de Științe Economice și Administrație Publică din cadrul Universității „Ștefan cel Mare” Suceava. (email: ionutb@seap.usv.ro).

Sorin Vlad este lector în cadrul Catedrei de Informatică a Facultății de Științe Economice și Administrație Publică, Universitatea “Ștefan cel Mare” Suceava (email: sorinv@seap.usv.ro).

Pentru $k=1, n$ execută

*) Inserează operația k în poziția corespunzătoare din schema parțială din cele k posibile care minimizează timpul parțial de execuție.



Deși algoritmul este de complexitate ($O(n^3m)$) soluțiile obținute sunt bune.

În rezolvarea problemei flow-shop, algoritmul NEH este privit ca cea mai bună soluție[4]. Algoritmul este aplicat de obicei pentru a determina o soluție inițială ce va fi folosită ca punct de plecare în metode de îmbunătățire a rezultatelor a rezultatelor cum ar fi *tabu search* [4] sau algoritmi genetici [6].

Principalul inconvenient al algoritmului NEH constă din faptul că este necesară evaluarea unui număr de $[n(n+1)/2]-1$ secvențe parțiale de execuție. Timpul de execuție crește rapid odată cu creșterea dimensiunilor problemei.

Pentru a reduce timpul de execuție, Taillard [5] a găsit o modalitate de îmbunătățire a algoritmului prin calculul secvențelor parțiale pentru fiecare iterație. Timpul de execuție se reduce însă secvențele parțiale vor trebui de asemenea reevaluate.

III. ALGORITMI GENETICI

Inteligența Artificială (AI) poate fi considerată ca fiind acel domeniu al Informaticii ce are ca obiectiv proiectarea sistemelor înzestrate cu anumite proprietăți pe care în mod obișnuit le asociem inteligenței umane: înțelegerea limbajului, învățarea, raționamentul, rezolvarea problemelor, demonstrarea teoremelor, etc.[1]

Algoritmi genetici reprezintă o importantă clasă din cadrul metodelor de căutare și optimizare. Ei reprezintă o transpunere în programare a principiilor biologice.

Acești algoritmi se deosebesc de tehnicile tradiționale de căutare prin următoarele caracteristici:

- optimizarea se face prin extragerea de noi puncte în spațiul de căutare, precum și exploatarea informațiilor din punctele găsite;
- au proprietatea de a fi paralelizați. Efectul lor este echivalent cu o căutare de soluții multiple din spațiul avut la dispoziție, fără a testa toate valorile acestui spațiu;
- sunt algoritmi ai căror soluții sunt obținute prin aplicarea unor operatori specifici asupra anumite valori generate aleatoriu;
- acționează asupra mai multor soluții simultan.

Structura acestui tip de algoritm este următoarea:

Pasul 1. Generarea populației inițiale (generare făcută aleatoriu, această populație fiind supusă unor transformări pe parcursul procesului, după un anumit număr de pași fiind obținută soluția finală);

Pasul 2. Selecția – Algoritmul genetic selecționează

indivizii unei populații în funcție de performanțele lor. Indivizii selecționați vor reprezenta o populație intermediară, populație a cărei cromozomi vor reprezenta “părinții” noii generații.

Pasul 3. Aplicarea operatorilor genetici – În acest pas o serie de operatori genetici sunt aplicați indivizilor selecționați la pasul 2. Printre cei mai utilizați operatori sunt cei de mutație și cei de încrucișare. În funcție de problema studiată pot apărea și alți operatori, cum ar fi: operatorul de inversare, operatorul de reordonare, etc.

Pasul 4. Selectarea populației care va părăsi sistemul;

Pasul 5. Repetarea pașilor 2,3,4, până la satisfacerea criteriului de optimalitate sau parcurgerea unui anumit număr de generații.




Fig. 1 Structura algoritmului genetic

Structura din figura 1 este una generală pentru acest tip de algoritmi, de aceea programatorul va trebui să adapteze acest model în funcție de necesități. Pentru aceasta trebuie să cunoască rolul fiecărei noțiuni în obținerea rezultatului final. Astfel vom avea:

Populația reprezintă un set de posibile soluții pentru problemă. De exemplu, dacă dorim să obținem minimul unei funcții $f: R_m \rightarrow R$, atunci fiecare obiect x ce aparține mulțimii R_m poate fi o posibilă soluție. De asemenea, orice subset P din mulțimea R poate reprezenta populația supusă prelucrărilor.

Indivizii (cromozomii) – reprezintă elementele componente ale populației. Din definiția populației putem desprinde faptul că “ x ”, fiind un punct din mulțimea R_m , reprezintă un individ (cromozom).

Urmașii (*offsprings*)- sunt indivizi obținuți prin aplicarea operatorilor genetici asupra populației studiate. Acești operatori diferă în funcție de problema studiată. De exemplu, un operator de încrucișare aplicat următorilor părinți:

$$\begin{aligned} &(x_1, x_2, \dots, x_k, x_{k+1}, \dots, x_m) \\ &(y_1, y_2, \dots, y_k, y_{k+1}, \dots, y_m), \end{aligned}$$

poate duce la obținerea următorilor urmași:

$$(x_1, x_2, \dots, x_k, y_{k+1}, \dots, y_m) \\ (y_1, y_2, \dots, y_k, x_{k+1}, \dots, x_m).$$

În exemplu de mai sus se observă faptul că încrucișarea s-a realizat pe poziția $k+1$.

Operatorii genetici reprezintă orice schimbare a vreunui cromozom. Operatorii pot fi aplicați asupra populației într-un mod aleatoriu, o mare influență asupra acestora având-o problema modelată.

Selecția reprezintă operația prin care anumiți indivizi vor fi aleși drept părinți pentru generarea urmașilor. Sunt selectați cei mai buni indivizi, ținându-se cont de funcția *fitness* folosită.

Finalitatea este determinată de scop. Algoritmul se poate opri după un anumit număr de pași, sau în momentul în care este atins un prag de eroare.

În implementarea algoritmilor genetici trebuie să ținem seama și de următoarele particularități[2]:

1. Algoritmii genetici sunt o clasă de algoritmi probabilistici care combină elemente de căutare dirijată și căutare aleatoare. Ei realizează un echilibru aproape optim între explorarea spațiului stărilor și exploatarea celor mai bune soluții găsite.
2. Algoritmii genetici sunt mai robusți decât alte metode existente de căutare dirijată și decât algoritmii clasici de optimizare.
3. Metodele de căutare bazate pe algoritmii genetici sunt caracterizate de faptul că ele mențin o populație de soluții potențiale. Metodele clasice de căutare acționează la un moment dat asupra unui singur punct din spațiul de căutare.
4. De regula, algoritmii genetici lucrează cu o codificare a elementelor din spațiul stărilor problemei și nu acționează direct asupra elementelor acestui spațiu.
5. Algoritmii genetici folosesc funcții de performanță obținute prin transformări simple ale funcției obiectiv. Nu este necesar ca funcția obiectiv să fie derivabilă. Nu sunt necesare nici proprietăți speciale de convexitate ale funcției obiectiv.
6. Algoritmii genetici sunt simplu de folosit.
7. Algoritmii genetici pot găsi soluții optime(sau aproape optime) cu o mare probabilitate.

IV. REZULTATE OBȚINUTE

În cele ce urmează vom prezenta rezultatele obținute în urma aplicării algoritmilor genetici asupra unor matrici ce conțin timpuri de rulare a unor procese pe anumite mașini. De asemenea se face și o comparație a rezultatelor obținute prin folosirea acestui algoritm cu rezultatele obținute prin algoritmul NEH, prezentat mai sus.

Operatorii genetici folosiți pentru optimizarea problemei studiate sunt mutația și încrucișarea. În paragrafele următoare se prezintă principalii operatori ce determină regenerarea

populației inițiale.

Considerăm reprezentarea din figura 2 ca fiind cromozomul inițial, supus mutațiilor.

6 1 9 3 4 5 0 7 8 2

Fig. 2 Cromozomul inițial

Primul operator de mutație își va face efectul în urma generării aleatoare a două gene ce alcătuiesc un cromozom. Prin interschimbarea acestor două gene va rezulta cromozomul copil. În figura 3 avem cromozomul copil obținut prin interschimbarea genei 4 cu gena 9 din cromozomul inițial.

6 1 4 3 9 5 0 7 8 2

Fig. 3 Cromozomul copil obținut prin interschimbarea dintre două gene ale cromozomului inițial

Pentru un al doilea operator de mutație pe care îl vom folosi vom recurge la găsirea timpului maxim de așteptare de pe ultimul procesor. Vom căuta acest timp maxim dorind să recurgem la eliminarea lui, prin poziționarea genei ce l-a provocat ca primă genă a cromozomului. Cromozomul obținut va avea forma celui din figura 4, considerând că timpul maxim de așteptare a fost atins la gena identificată prin 3.

3 6 1 9 4 5 0 7 8 2

Fig. 4 Cromozomul obținut prin aplicarea celui de-al doilea operator de mutație

Tot pentru a elimina acel timp maxim putem recurge la rearanjarea genelor începând cu ultima situată înainte de locația unde se atinge timpul maxim și până la sfârșitul cromozomului. Rezultatul obținut poate fi unul de forma celui din figura 5.

6 1 0 2 4 9 5 3 7 8

Fig. 5 Cromozom copil obținut prin mutație.

Pe lângă operatorul de mutație, un alt operator des folosit este cel de încrucișare. În exemplu nostru generăm doi cromozomi pe care îi vom supune operației de încrucișare. Cromozomii inițiali sunt cei din figura 6, iar rezultatele sunt prezentați în figura 7.

6 1 9 3 4 5 0 7 8 2

0 1 5 9 2 3 4 6 7 8

Fig. 6 Cromozomi supuși operației de încrucișare.

6 1 9 3 0 5 2 4 7 8

0 1 5 9 6 3 4 7 8 2

Fig. 7 Cromozomi obținuți prin încrucișare.

După aplicarea operatorilor genetici asupra populației, datele trebuie ordonate ținând cont de valoarea funcției *fitness* calculată pentru fiecare cromozom. De asemenea, la fiecare

pas se recomandă generarea aleatoare a unui anumit număr de indivizi pentru a evita obținerea unui optim local pentru funcția de evaluare a cromozomilor.

Probabilitatea de mutație a unui cromozom este de 0,5 , în timp ce cea de încrucișare ajunge la 0,2.

În tabelul 1 sunt prezentate rezultatele obținute la planificarea proceselor pe un anumit număr de mașini cu ajutorul algoritmilor genetici și algoritmului NEH.

Tabel 1 Rezultatele obținute, pentru diferite cazuri, folosind algoritmi genetici și NEH

Nr. Procese x Nr. Mașini	NEH	Cel mai bun rezultat obținut cu AG	Medie obținută cu AG	Număr indivizi din populație	Număr generații
10 x 2	663	663	663	20	100
10 x 4	728	728	728	20	100
20 x 5	1373	1350	1350	40	100
20 x 10	1638	1611	1630	40	200
30 x 10	2179	2121	2153	50	200
50 x 10	3190	3132	3142	60	500
50 x 20	4082	3947	3975	100	1000
100 x 10	5898	5898	5898	100	1000
100 x 20	7064	6807	6875	200	1000
100 x 40	7064	6788	6827	400	1000

Se observă că în 3 dintre cazurile studiate rezultatele obținute prin aplicarea celor doi algoritmi coincid, în timp ce în alte 7 cazuri rezultatele obținute prin aplicarea algoritmilor genetici sunt mai bune. În funcție de problemă numărul de indivizi din populația studiată, precum și numărul de generații diferă. Datele din tabelul 1 sunt reprezentate grafic în figura 8.




Fig. 8 Rezultatele celor 2 algoritmi.

Marele dezavantaj al algoritmilor genetici este dat de timpul de rulare mult mai mare decât timpul execuției unui algoritm clasic.

În figura 9 se observă viteza de convergență a algoritmilor genetici în cazul planificării a 50 de procese pe 20 de mașini , folosindu-se 500 de generații.




Fig. 9. Rezultate obținute pentru 50 procese x 20 mașini (500 generații).

V. CONCLUZII

Din cele prezentate mai sus se observă că algoritmi genetici furnizează rezultate destul de bune la anumite probleme de planificare. În cazul problemelor NP-complexe este recomandată folosirea acestui tip de algoritmi în defavoarea altor algoritmi clasici. Problema flow-shop urmărește să planifice un număr de procese pe un anumit număr de mașini astfel încât timpul de rulare a acestora să fie cât mai mic. Pentru un număr mic de mașini există algoritmi care oferă rezultate foarte bune, cum ar fi algoritmul lui Johnson. Dar prin creșterea numărului de mașini problema devine din ce în ce mai complexă, acest lucru ducând la obținerea de rezultate nesatisfăcătoare în cazul folosirii unor metode clasice. În acest caz se recomandă folosirea algoritmilor genetici, chiar dacă timpul de rulare crește destul de mult. Marea majoritate a problemelor de planificare se pot rezolva cu ajutorul acestor tehnici inspirate din selecția naturală. Algoritmi genetici presupun efectuarea unui număr mare de calcule și acest lucru limitează utilizarea lor în anumite aplicații. Efortul de calcul este dependent de valorile setate pentru parametrii algoritmului: dimensiunea populației, presiunea de selecție, etc. Diminuarea, de exemplu, a dimensiunii populației ar determina reducerea timpului de execuție, dar ar putea afecta dramatic acuratețea rezultatelor algoritmului. O soluție pentru reducerea timpilor de execuție, care să nu afecteze acuratețea și viteza de convergență a algoritmului, ar fi paralelizarea algoritmilor genetici. Acest lucru va duce, în final, la micșorarea timpului de rulare a aplicațiilor ce realizează planificarea dorită, în funcție de viteza de comunicație dintre procesoare. Paralelizarea poate fi realizată urmărind trei mari

direcții: algoritmi genetici globali, algoritmi genetici bazați pe migrare și algoritmi genetici bazați pe migrație.

REFERINȚE

- [1] Dumitrescu, D., Principiile inteligenței artificiale, Ed. Albastră, 2002
- [2] Dumitrescu, D., Algoritmi genetici și strategii evolutive- apucații în Inteligența Artificială și în domenii conexe, Ed. Albastră, 2006
- [3] J. Grabowski, M. Wodecki, A very fast tabu search algorithm for the permutation flow shop problem with makespan criterium,, Computer & Operation Research, 31 (2004), 1891-1909
- [4] Rubén Ruiz, Concepción Maroto, Javier Alcaraz, Solving the flowshop scheduling problem with sequence dependent setup times using advanced metaheuristics, European Journal of Operational Research 165(1): 34-54 (2005)
- [5] É.D. Taillard, Some efficient heuristic methods for the flow shop sequencing problem, European Journal of Operational Research, 1990
- [6] Wang L, Zheng DZ, A modified evolutionary programming for flow shop scheduling, International Journal of Advanced Manufacturing Technology, 2003