DIPLOMSKI SEMINAR

Izrada rasporeda nastave za osnovne i srednje škole

Siniša Pribil
Mentor: Doc.dr.sc. Marin Golub
Voditelj: Mr.sc. Marko Čupić

SVEUČILIŠTE U ZAGREBU
Fakultet elektrotehnike i računarstva

9. lipnja 2011.

Sadržaj

Uvod

- današnji život određen je različitim oblicima rasporeda
- rasporedi u obrazovnim ustanovama
  - osnovno- i srednje-školski
  - fakultetski
  - raspored fakultetskih ispita
- osnovne i srednje škole
  - izrada rasporeda složen i dugotrajan posao
  - većina još uvijek izrađuje ručno
  - može li se automatizirati?
- suradnja s pet osnovnih i srednjih škola u Zagrebu i okolici

Pojednostavljen problem

- m razreda $(c_1, \ldots, c_m)$, n nastavnika $(t_1, \ldots, t_n)$, p raspoloživih sati, $R_{m\times n}$ – matrica predavanja

$$\begin{aligned} &\text{pronađi} \quad X_{m\times n\times p} \\ \text{t. d.} \quad &\forall(i,j) \quad \sum_{k=1}^{p} x_{ijk} = r_{ij}, \\ &\forall(i,k) \quad \sum_{j=1}^{n} x_{ijk} \leq 1, \\ &\forall(j,k) \quad \sum_{i=1}^{m} x_{ijk} \leq 1 \text{ i} \\ &\forall(i,j,k) \quad x_{ijk} = 0 \text{ ili } 1. \end{aligned}$$

Grafički prikaz pojednostavljenog problema

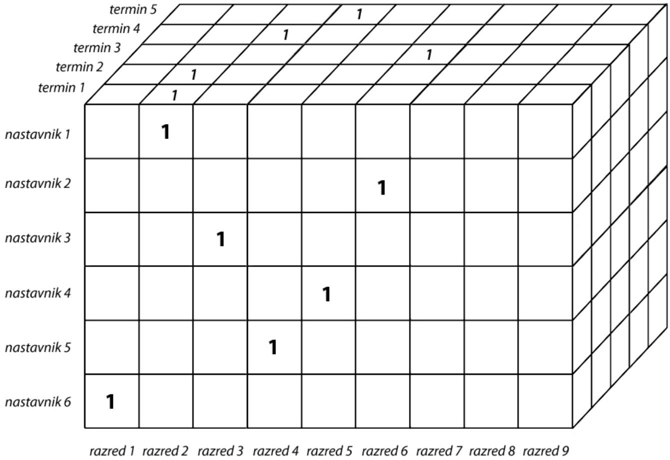

Osnovni problem

- $C_{m \times p}$ – matrica raspoloživosti razreda, $T_{n \times p}$ – matrica raspoloživosti nastavnika

$$
\begin{aligned}
\text{pronađi} \quad & X_{m \times n \times p} \\
\text{t. d.} \quad \forall(i,j) \quad & \sum_{k=1}^{p} x_{ijk} = r_{ij}, \\
\forall(i,k) \quad & \sum_{j=1}^{n} x_{ijk} \leq c_{ik}, \\
\forall(j,k) \quad & \sum_{i=1}^{m} x_{ijk} \leq t_{jk} \text{ i} \\
\forall(i,j,k) \quad & x_{ijk} = 0 \text{ ili } 1.
\end{aligned}
$$

Dodatna ograničenja

- neprekidan raspored
- raspoređivanje učionica
  - o dvorana $(h_1, \ldots, h_o)$, $H_{o \times p}$ – matrica raspoloživosti dvorana

$$\text{pronađi} \quad X_{m \times n \times p \times o}.$$

$$\forall (i, j, k) \quad \sum_{l=1}^{o} x_{ijkl} \leq h_{lk} \text{ i}$$

$$\forall (x_{ijkl}) \quad \text{t. d. } x_{ijkl} = 1 \rightarrow E_{ij} \subseteq F_l$$

Dodatna ograničenja

- dijeljena, spojena i usporedna predavanja
  - dijeljenje razreda na manje grupe i spajanje tako nastalih grupa (npr. vjeronauk, etika, strani jezik. . .)
    - istodobno u različitim učionicama
    - u različitim terminima, u skladu s neprekidnošću rasporeda za sve učenike (ako je zadano)
  - usporedna predavanja unutar istog razreda
    - iz dva ili više predmeta (npr. vježbe iz informatike i fizike. . .)
    - dijeljenje razreda, ali bez spajanja s drugim grupama
- upravljanje opterećenjima

Oblici pristupa i složenost

- sustavi
  - automatizirani
  - interaktivni
- pristupi problemu
  - pretraga
  - optimizacija
    - zadovoljenje čvrstih ograničenja
    - optimizacija mekih ograničenja
- temeljni problem
  - "Postoji li odgovarajuće rješenje?"
  - pojednostavljeni problem – polinomijalan
  - osnovni problem – NP potpun

Izravne heuristike

- ljudski način rješavanja problema
- izrada rasporeda pomoću tri postupka:
  - A: rasporedi *najsloženija* predavanja u termine koji su za njih *najpoželjniji*
  - B: kada se u pojedini termin može rasporediti samo jedno predavanje, smjesti to predavanje u navedeni termin
  - C: premjesti već raspoređeno predavanje u drugi slobodan termin kako bi se oslobodio termin za novo, neraspoređeno predavanje

Simulirano kaljenje

- oponaša postupak kaljenja metala
  - veća temperatura – veća sloboda oblikovanja
  - temperatura ispod kritične – poprimanje trajnog oblika

$$p_{prihvati} = \begin{cases} 1 & \text{ako } f(s') \leq f(s) \\ e^{-\frac{f(s')-f(s)}{T}} & \text{inače} \end{cases}$$

- uvjeti završetka
  - pronalazak zadovoljavajućeg rješenja
  - pad temperature ispod kritične razine
  - vremensko ograničenje

Tabu pretraga

- bilježenje prethodno učinjenih koraka (tabu lista)
    - zabranjeno ponavljati iste korake određeno vrijeme
    - tabu korak se prihvaća ako značajnije doprinosi poboljšanju kvalitete
- sadržaj tabu liste
    - cjelokupna rješenja
    - vrste promjena nad rješenjem
    - značajke rješenja

Genetski algoritam

- inspiriran procesom prirodne evolucije
  - populacija jedinki (rješenja)
  - potomci nasljeđuju značajke roditelja
- tri evolucijska operatora
  - selekcija
  - križanje
  - mutacija
- dvije inačice algoritma
  - generacijski
  - algoritam stacionarnog stanja

Zaključak

- izrada rasporeda veliki je problem za škole
    - potreba za automatiziranim sustavom
- u sklopu rada:
    - održani sastanci s predstavnicima osnovnih i srednjih škola u Zagrebu i okolici
    - prikupljeni zahtjevi
    - analiziran problem
    - razmotreni oblici pristupa rješavanju problema
- zaključak (u suradnji s Tus (2011)):
    - potreba za izgradnjom novog sustava za izradu rasporeda

Hvala na pažnji!

Literatura

*Bibliography

D. Abramson. Constructing school timetables using simulated annealing: sequential and parallel algorithms. *Management Science*, 37(1):98–113, 1991. ISSN 0025-1909.

D. Abramson, J. Abela, and CSIRO (Australia). Division of Information Technology. *A parallel genetic algorithm for solving the school timetabling problem*. Citeseer, 1993. ISBN 0868575364.

M. Bufé, T. Fischer, H. Gubbels, C. Häcker, O. Hasprich, C. Scheibel, K. Weicker, N. Weicker, M. Wenig, and C. Wolfangel. Automated solution of a highly constrained school timetabling problem-Preliminary Results. *Applications of Evolutionary Computing*, pages 431–440, 2001.

A. Colorni, M. Dorigo, and V. Maniezzo. A genetic algorithm to solve the timetable problem. *Politecnico di Milano, Milan, Italy TR*, pages 90–060, 1992.

A. Colorni, M. Dorigo, and V. Maniezzo. Metaheuristics for high school timetabling. *Computational Optimization and Applications*, 9(3):275–298, 1998. ISSN 0926-6003.

D. de Werra. An introduction to timetabling. *European Journal of Operational Research*, 19(2):151–162, 1985. ISSN 0377-2217.

S. Even, A. Itai, and A. Shamir. On the complexity of time table and multi-commodity flow problems. In *16th Annual Symposium on Foundations of Computer Science*, pages 184–193. IEEE, 1975.

J.E. Hopcroft and R.M. Karp. An $n^{5/2}$ algorithm for maximum matchings in bipartite graphs. *SIAM Journal on Computing*, 2:225, 1973.

W. Junginger. Timetabling in Germany: a survey. *Interfaces*, pages 66–74, 1986. ISSN 0092-2102.

O. Rossi-Doria, M. Sampels, M. Birattari, M. Chiarandini, M. Dorigo, L. Gambardella, J. Knowles, M. Manfrin, M. Mastrolilli, B. Paechter, et al. A comparison of the performance of different metaheuristics on the timetabling problem. *Practice and Theory of AutomatedTimetabling IV*, pages 329–351, 2003.

A. Schaerf. *Tabu search techniques for large high-school timetabling problems*. Computer Science, Department of Interactive Systems, CWI, 1996.

A. Schaerf. A survey of automated timetabling. *Artificial Intelligence Review*, 13(2):87–127, 1999. ISSN 0269-2821.

A. Tus. *Analiza zahtjeva i postojećih rješenja u izradi rasporeda sati za škole, seminarski rad u sklopu predmeta Seminar*. Zavod za elektroniku, mikroelektroniku, računalne i inteligentne sustave, FER, 2011.

Simulirano kaljenje – algoritam

$s \leftarrow$ nasumično početno rješenje
$T \leftarrow T_0$
dok (!*uvjetZavrsetka*) **radi**
  azurirajTemperaturu(T)
  $s' \leftarrow$ *susjednoRjesenjeOd*(s)
  ako $f(s') < f(s)$ **tada**
    $s \leftarrow s'$
  inače
    $s \leftarrow s'$ s vjerojatnošću $p(T, s, s') = e^{-\frac{f(s')-f(s)}{T}}$
  završi ako
završi dok
vrati s

Simulirano kaljenje – ostali faktori

- početna temperatura (prema Rossi-Doria et al. (2003)):

$$p = \frac{1}{e} = e^{-\frac{0.02 * f(s_r)}{T}} \rightarrow T = 0.02 * f(s_r)$$

- stupanj hlađenja:

$$T_{n+1} = \alpha \times T_n, \quad 0 < \alpha < 1$$

- trajanje trenutne temperature:
  - odluka na temelju statističke obrade

Mutacija rasporeda

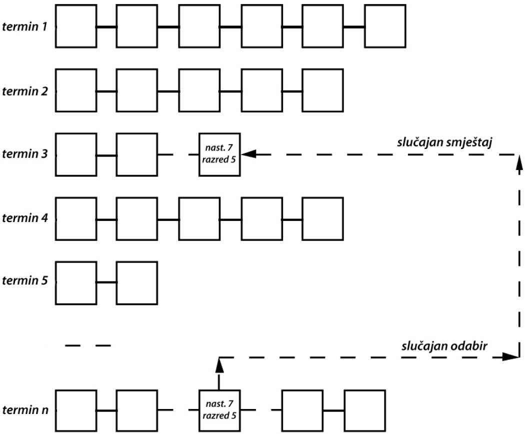

Tabu pretraga – algoritam

$s \leftarrow$ nasumično početno rješenje
$L \leftarrow \emptyset$
dok (!*vremenskoOgranicenje*) **radi**
  za n susjeda od s **radi**
    $s_i \leftarrow$ i-ti susjed od s
  završi za
  ako $\exists s_j \mid (zadovoljavaTeznju(s_j)\ \&\&\ \forall s_i (f(s_j) \leq f(s_i)))$ **tada**
    $s \leftarrow s_j$
  inače
    $s \leftarrow$ najbolje ne-tabu rješenje od svih s_i
  završi ako
  $L \leftarrow L \bigcup s$
  $L \leftarrow L \setminus \{$najstariji element iz L$\}$
završi dok
vrati s

Genetski algoritam – algoritam

$P \leftarrow$ populacija n nasumičnih početnih rješenja
dok (!*uvjetZavrsetka*) **radi**
  $P_n \leftarrow \emptyset$
  za $i = 1$ do n **radi**
    $r_{i1}, r_{i2} \leftarrow$ odabir dva roditelja proporcionalno njihovoj kvaliteti
    (bolje jedinke imaju veće šanse za stvaranje potomstva)
    $d_i \leftarrow krizanje(r_{i1}, r_{i2}, \alpha)$
    $d_i \leftarrow mutacija(d_i, \beta)$
    $P_n \leftarrow P_n \bigcup d_i$
  završi za
  $P \leftarrow P_n$
završi dok
vrati najbolju jedinku iz P

Genetski algoritam – križanje binarnih kromosoma

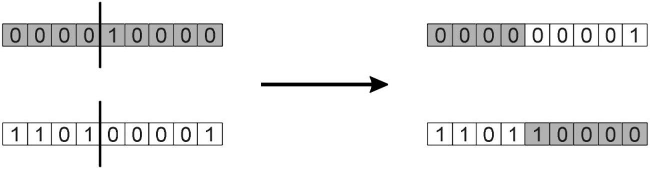

Genetski algoritam – križanje hibridnih kromosoma