

ALGORITMI ZA ISKANJE REZERVIRANIH BESED

M. GAMS

UDK: 519.688

INSTITUT „JOŽEF STEFAN“, JAMOVA 39, LJUBLJANA

V članku so opisani algoritmi za iskanje rezerviranih besed. Osnovna algoritma sta binarno iskanje in iskanje z razpršenimi tabelami. V članku so opisane izboljšave teh dveh osnovnih algoritmov. Podana je tudi njihova časovna in prostorska analiza.

ALGORITHMS FOR SEARCHING FOR RESERVED WORDS. This article describes algorithms for searching for reserved words. Basic algorithms are binary search and hash search. This article describes basic algorithms with their improvements and provides time and memory requirements analysis.

1. Uvod

V računalniških programih pogosto srečamo rezervirane besede. To so besede, ki imajo poseben, rezerviran pomen. Take besede srečamo v prevajalnikih, urejevalnikih, operacijskih sistemih itd. Rezervirane besede so del teksta, npr. programa v programskem jeziku, zato morajo računalniški programi vsebovati postopke za iskanje rezerviranih besed. Osnovna algoritma za iskanje rezerviranih besed sta binarno iskanje in iskanje z razpršenimi tabelami. Z izboljšavami teh dveh algoritmov je mogoče doseči precejšnje časovne prihranke.

2. Opis algoritmov

Najprej bomo opisali osnovna algoritma in nato njune izboljšave. Algoritme bomo opisovali v Pascalu. Ker pa bomo preiskovali izrazne možnosti tega jezika, so to posebej označeno. V tem poglavju bomo sicer tudi o kompleksnosti algoritmov. S tem pojmom bomo označili povprečno število primerjav neznane besede z rezerviranimi.

2.1. Binarno iskanje

Opis algoritma:

```
lower := 1; higher := bottom;
found := false;
while (lower <= higher) and not found do
begin
  middle := (lower + higher) div 2;
  if words[middle] > unknownWord
  then higher := middle
  else if words[middle] < unknownWord
  then lower := middle
  else found := true
end;
```

WORDS

```
lower => |AND|
|ARRAY|
|...|
|...|
middle => |...|
|...|
|...|
|...|
higher => |WITH|
```

Opomba:

- na vsodni obstoječih Pascalovih prevajalnikih operatorja "<" in ">" nista implementirana za prirejanje sestavljenih tipov,
- rezervirane besede v tabeli "WORDS" morajo biti urejene po abecednem redu,
- spremenljivki "lower" in "higher" morata biti pred začetkom izvajanja binarnega iskanja prirejeni na vrh, oziroma dno tabele.

Kompleksnost algoritma za binarno iskanje je reda velikosti $\log(n)$, kjer je n število rezerviranih besed. Ker je rezerviranih besed običajno nekaj deset, je $\log(n) < 5$ ali 6.

Najbolj običajen trik za optimizacijo iskanja je grupiranje rezerviranih besed v skupine. Eden principov za grupiranje v skupine je po dolžini besed, tako da so znotraj iste skupine besede iste dolžine, urejene po abecednem redu. Algoritem za binarno iskanje je potrebno samo malenkostno spremeniti. Binarno iskanje vršimo v tabeli "WORDS" tako, da

pred izvajanjem osnovnega algoritma priredimo spremenljivkam "lower" in "higher" vrednosti iz vnosa generirane tabele, ki vsebuje indekse začetka in konca skupin besed iste dolžine. Na primer, če je "1" dolžina neznane besede, bo "lower := lensht[1]" in "higher := lensht[1] - 1". Primer za jezik Pascal je shematično prikazan malo naprej.

LENGTH	WORDS
2 1 1	IOO
3 1 7	IIF
4 1..1	IIN
5 1..1	IOF
..1..1	IOR
	ITO
	IAND
	1..
	1..

Za realne primere se kompleksnost algoritma približno dvakrat zmanjša in je med 2 in 3.

Drugi način grupiranja je po prvi ali po prvih dveh črkah. V prvem primeru je tabela za določanje indeksov v tabeli WORDS razdeljena na 26 in v drugem na 676 delov. Dodatno potrebujemo 26 ali 676 celic spomina, iskanje neznane besede pa ima kompleksnost med 2 in 1. Možne so še razne kombinacije, npr. grupiranje po dolžini in po prvi črki itd.

TWOCHARS	WORDS
AA 1 01	IAND
AB 1 01	IARRAY
AC 1 01	1..
.. 1..1	1..
.. 1..1	
AN 1 11	
AO 1 01	
AP 1 01	
AQ 1 01	
AR 1 21	
.. 1..1	
.. 1..1	

2.2. Iskanje z razpršenimi tabelami

Osnovni algoritem iskanja z razpršenimi tabelami temelji na funkciji "h", ki preslika v našem primeru besede v indekse tabele. Kompleksnost takih algoritmov je običajno kar konstanta. Kompleksnost je 1 kadar je funkcija h injektivna ($h(w1) \neq h(w2)$). Običajno imajo razpršitvene funkcije lastnosti, ki so v povprečju blizu injektivnosti, tako da se lahko približajo kompleksnosti 1. Druga pomembna lastnost razpršitvenih funkcij je to, da običajno razpršijo podatke v precej večjo tabelo, oziroma da je v tabeli precej praznih mest. Od tod tudi ime "razpršene tabele".

Kadar je razpršitvena funkcija injektivna, navadno rečemo, da je "popolna" (perfect). Kadar je razpršitvena funkcija surjektivna, rečemo, da je "minimalna". Minimalna razpršitvena funkcija ima v našem primeru tabelo "WORDS" polno zasedeno.

V zadnjih letih je nekaj odkritij povečalo zanimanje za minimalne ali skoraj minimalne popolne razpršitvene funkcije [1,2,3]. V [1] je opisana minimalna razpršitvena funkcija, implementirana na rezerviranih besedah jezika Pascal. Razpršitvena funkcija je oblike

$h(\text{Word}) = \text{value}[\text{Word}[1]] + \text{lensht} + \text{value}[\text{Word}[\text{lensht}]]$

"lensht" je dolžina neznane besede "Word", "Word[i]" je i-ta črka besede "Word", "value[letter]" je izbrana vrednost črke "letter".

Običajno funkcija ne more biti popolna, kadar obstajata dve rezervirani besedi enake dolžine, ki imata paroma enaki prvi in zadnji črki. V [2] je pokazano, da obstaja še več drugačnih protiprimerov, torej postopek iskanja razpršitvenih funkcij na zgornji način ne jamči rešitve. V [3] je omenjena metoda, ki nima te slabosti, vendar je tako generirana funkcija časovno zahtevnejša.

Problem iskanja razpršitvene funkcije je problem prirejanja vrednosti posameznim črkam. Denimo, da imamo samo 20 različnih začetnih in končnih črk rezerviranih besed, ter da vsaki lahko priredimo največ 20 različnih vrednosti. Kompleksnost preprostega algoritma, ki preračuna vse variante, je 20×20 (dvajset na dvajset), torej praktično neizvedljivo. Napišimo ga:

```
repeat
  if overlap then letter := pred(letter)
  else begin letter := succ(letter);
           value[letter] := -1
        end;
repeat
  value[letter] := value[letter] + 1;
  checkOverlapping(overlap, value, words)
until not overlap or
  (value[letter] > maxvalue)
until not overlap and (letter = 'z')
```

Osnovni algoritem lahko pohitimo z različnimi triki. Namesto zaporednega izbiranja črk začnemo z najbolj posostimi. Nadaljne izboljšave niso objavljene v literaturi, čeprav so v praksi najbolj uporabljane. Najbolj učinkovito pohitritev imenujem "superbacktrack". Kadar se dve rezervirani besedi prekrivata tako, da ju ne moremo ločiti s spreminjanjem vrednosti tekoče črke, moramo spremeniti vrednost črke, ki nastopa v prirejanju in smo ji zadnji določili vrednost. Posledje si pri-mer:

```
value[letter]
-----
e | 0
r | 1
t | 4
f | ?  <== tekoča črka
```

```
w1 = for
w2 = file
```

```
h(w1) = value[f] + 3 + value[r] + value[f] + 4
h(w2) = value[f] + 4 + value[e] = value[f] + 4
```

"Superbacktrack" v takem primeru poveča vrednost črke "r" za 1.

Avtor je opazil še en koristen recept. Ko zasledujemo izvajanje algoritma, opazimo, da so nekatera zaporedja črk zelo neprijetna. Takrat program spreminja vrednosti črk korak za korakom brez "superbacktracka". Takrat je najbolje prekiniti izvajanje in spremeniti vrstni red prirejanja vrednosti črkam.

Tako je za generiranje minimalne popolne razpršitvene funkcije za Pascalove rezervirane besede avtorjev program porabil le nekaj sekund. Poslejmo si primer, ko naprej izberemo najmanjšo možno vrednost razpršitvene funkcije 3:

VALUE	WORDS
1 IEI 01	
2 IPI 01	
3 IDI 01	IEND
4 ITI 11	IELSE
5 INI 31	ITYPE
6 IOI 81	IPACKED
7 IRI 61	INOT
8 IFI 111	ITHEN
9 ILI 111	IPROCEDURE
10 IAI 151	IDD
11 ICI 191	ITO
12 IUI 191	IRECORD
13 IMI 231	IREPEAT
14 IVI 251	IDOWNTD
15 IWI 141	IFILE
16 IBI 211	IQR
17 IQI 191	INIL
18 IHI 151	IAND
19 ISI 311	IWHILE
20 IUI 201	IFOR
21 IYI 171	IOF
22 IJI 01	IFUNCTION
23 IKI 01	ICASE
24 IQI 01	IIN
25 IXI 01	ICONST
26 IZI 01	IMOD
27	ILABEL
28	IDIV
29	IBEGIN
30	IPROGRAM
31	IGOTO
32	IF
33	IWITH
34	IVAR
35	ISET
36	IUNTIL
37	IAARRAY

Za Pascalove rezervirane besede znamo enostavno in hitro določiti minimalno popolno razpršitveno funkcijo. Kaj pa če imamo v rezerviranih besedah tudi besede kot "odr" in "car" ali "fi" in "if"? Očitno moramo izbrati drugačno obliko razpršitvene funkcije. Nato poskusimo generirati tabelo "value". Ker nam postopek ne jamči rešitev, prav lahko poskusimo zaman. V takih primerih je smiselno najprej iskati popolno razpršitveno funkcijo, ki ni minimalna. Tabela "WORDS" je zdaj dimenzije $N + NEKAJ$, kjer je N število rezerviranih besed. Ko najdemo eno rešitev, lahko zmanjšujemo "NEKAJ", dokler se najdemo rešitev. Da ne bi trošili preveč spomina, si pomagamo še z naslednjim trikom:

VALUE	WORDS
MIN	11
MIN + 1	01
MIN + 2	21
...	...
...	...
MIN+NEKAJ	1351

Tako poročimo še $N + NEKAJ$ celic spomina.

3. Podrobnejša časovna in prostorska analiza algoritmov

Do sedaj smo govorili le o povprečnem številu potrebnih primerjanj neznane besede z rezerviranimi. To smo označili s "kompleksnostjo algoritma". Sledi podrobnejša analiza algoritmov. Za eno operacijo bomo šteli eno primerjanje, eno prirejanje, eno računsko operacijo (+, *...), en doses polja itd. Te operacije časovno niso enakovredne, zato so ocene okvirne in odvisne od računalnika. Privzeli bomo še, da en znak zavzema eno besedo spomina, da je rezervirana beseda sestavljena iz 10 znakov in da je vseh rezerviranih besed 32.

Ocenimo število osnovnih operacij za primerjanje besed med seboj:

```
while (a[i]=b[i]) and (i<dimWord) do
  i := i + 1;
```

Imamo:

```
1 prirejanje (i=)
1 rač.op. (+)
1 log.op. (and)
2 primerjanji (=, <)
2 dosesa polja ([i])
+1 za kontrolni konstrukt "while"
```

8 osnovnih operacij

Za enaki besedi nateloma porabimo toliko primerjanj kot je dimenzija besede (maksimalna dovoljena dolžina). Za različni besedi porabimo bistveno manj primerjanj, v povprečju bomo za naše ocene vzeli 1,5.

A - neznana beseda je rezervirana
B - neznana beseda ni rezervirana

ALGORITEM	ŠTEVILO OPERACIJ	CELIC SPOMINA
	A	B
binarno	190	125
+ po dolžini	140	60
+ po prvi črki	120	55
+ po prvi črki + dolž.	80	20
+ po prvih dveh črkah	55	10
minim. pop.	55	12
razprš. f.	57	14
popolna		
razprš. f.	57	14

Opombe:

- ocene so okvirne, ker so zelo odvisne od oblike rezerviranih besed itd.
- Konkretno izvedbe algoritmov lahko malo pohitimo z enostavnimi triki, ki so v časovni analizi upoštevani. Tudi, kadar v povprečju dostikrat prirejamo enake besede, bomo primerjanje naredili takole:

```
while (unknownWord[i] = WORDS[index,i]) and
  (WORDS[index,i] <> ' ') do
  i := i + 1;
```

Tako primerjanje precej pohitimo.

- v oceni je bila privzeta taka oblika razpršitvene funkcije kot za Pascalove rezervirane besede.
- v praktični uporabi algoritmov, npr. pri prevajalnikih, odpade večji del potrošene časa na branje, tako da so prihranki manjši.

Praktični rezultati:

Skupina študentov (M.Bradeško, B.Drenuž, M.Hrvatini, T.Kokalj) je merila razmerje med osnovnim binarnim iskanjem in poročno razpršitveno funkcijo za Pascalove rezervirane besede. Razmerje se je sukalo od 1:8 do 1:9 glede na način generiranja testnih besed od samih rezerviranih do samih nerezerviranih. To razmerje ustreza teoretično izračunanemu.

Rad bi se zahvalil tudi I. Mozetiču in N. Lavrač za konstruktivne pripombe.

Zaključek analize:

Natančna analiza algoritmov za iskanje rezerviranih besed da določeno prednost popolnim minimalnim ali skoraj minimalnim razpršitvenim funkcijam. Algoritem z razdelitvijo rezerviranih besed po prvih dveh črkah je časovno celo malenkost hitrejši, vendar troši bistveno več spominskega prostora. Porodne razpršitvene funkcije imajo le to dodatno neprijetnost, da moramo najti obliko razpršitvene funkcije in da moramo prirediti vrednosti črkam. To pa je običajno delo nekaj dni.

4. Zaključek

Praktični in teoretični rezultati dajejo prednost uporabi algoritmov z minimalnimi ali skoraj minimalnimi razpršitvenimi funkcijami za iskanje rezerviranih besed. Sama uporaba razpršitvene funkcije je 5 do 10 krat hitrejša od osnovnega binarnega iskanja. Zaradi počasnega branja je v praktičnih primerih prihranek precej manjši, vendar se vedno upoštevanja vreden. Zato je smiselno pohitriti obstoječo programska oprema s popolno razpršitveno funkcijo.

Literatura:

1. R.J.Cichelli: Minimal Perfect Hash Functions made simple, CACM, Vol.23, Num.1, Januar 1980, str. 17-18.
2. G.Jaesohke, G.Osterburs: On Cichelli's Minimal Perfect Hash Function Method, CACM, Vol.23, Num.12, December 1980, str. 728-729.
3. G. Jaesohke: Reciprocal Hashing: A Method For Generating Minimal Perfect Hashing Functions, CACM, Vol.24, Num.12, December 1981, str. 829-833.