

Skiplistor

Grupparbete i Matematisk statistik och diskret matematik / Matematisk statistik, ht 05

Det här projektet handlar om så kallade skiplistor, som är en datastruktur för lagring av elementen i en ordnad lista. En ordentlig beskrivning av hur skiplistor fungerar hittar ni i avsnitt 8.6 i *Data Structures and Algorithms in Java* av Goodrich and Tamassia, som är kurslitteratur på Datastrukturer. Chalmersbiblioteket har boken i elektronisk form. (Välj Books24x7 BusinessPro bland chalmersbibliotekets E-boksamlingar eller gå in i Chans.) Nedan följer en kortfattad icke-datalogisk beskrivning av hur listan ser ut, mest för att introducera terminologin som används här.

Antag att vi har n stycken tal vi vill lagra i en skiplista. Ordna talen och skapa en lista med n noder, där varje nod innehåller ett av talen. Detta är nivå 0 i skiplistan. Singla en slant för varje nod: blir det krona så skapas en ny nod på nivå 1 som innehåller samma tal, dvs med sannolikhet $1/2$ kopieras en nod upp till nivå 1, oberoende av vad som sker med övriga noder. Fortsätt sedan på samma sätt: varje nod på nivå i får följa med till nivå $i + 1$ med sannolikhet $1/2$. Varje nivå ska dessutom börja med $-\infty$ och sluta med $+\infty$.

Uppgift 1 och 2 kan ni klara första veckan av kursen medan uppgift 3, 4 och 5 kräver kunskaper om stokastiska variabler och görs lämpligen vecka 2.

1. Diverse sannolikheter (vecka 1)

- Vad är sannolikheten att exempelvis det första talet når upp till nivå i (eller högre)?
- Om man vet att k stycken tal når nivå i , på hur många sätt kan man då välja ut dessa tal?
- Vad är sannolikheten att det finns k stycken noder på nivå i , där $k = 0, 1, \dots, n$ och $i = 0, 1, \dots$, om man inte räknar med ändnoderna $-\infty$ och $+\infty$?

2. Värsta fallet (vecka 1)

Det värsta som kan inträffa i en skiplista, med avseende på tidsåtgång vid sökning, är att alla tal når upp till samma nivå.

- Vad är sannolikheten att exempelvis det första talet når upp till nivå i men inte högre?
- Vad är sannolikheten att alla når nivå i men ej $i + 1$, där $i = 0, 1, 2, \dots$?
- Vad är sannolikheten att alla tal når upp till samma nivå i i en lista med n stycken tal?

Ledtråd: Om alla når upp till samma nivå, betyder det att ingen når nivå 1, eller att alla når nivå 1 men ej 2, eller att alla når nivå 2 men ej 3, eller att alla når nivå 3 men ej 4, eller ...

Utnyttja (a) och att "eller = \cup ".

3. Minnesutrymme (vecka 2)

- (a) Låt X beteckna antalet noder på nivå i . I uppgift 1a har ni räknat på sannolikheten att $X = k$. Vad kallas den stokastiska variabeln X och vilka parametrar har den?
- (b) Vad är förväntat antal noder på nivå i , $i = 0, 1, \dots$, även här exklusive ändnoder? Ledtråd: Utnyttja väntevärdet i binomialfördelningen.
- (c) Vad är förväntat totalantal noder i skiplistan, exklusive ändnoder?
- (d) Hur stor plats kräver en skiplista med n stycken tal? (I termer av stora ordo O .)

4. Skiplistans höjd (vecka 2)

- (a) Låt Y beteckna höjden på första stapeln. I uppgift 2a har ni räknat på sannolikheten att $Y = i$. Vad kallas den stokastiska variabeln $X = Y + 1$ och vilken är dess parameter?
- (b) Förklara varför höjden i en skiplista som består av n stycken tal, H_n , kan beskrivas som $H_n = \max\{X_1, \dots, X_n\} - 1$, där X_1, \dots, X_n är oberoende och geometriskt fördelade stokastiska variabler med parameter $1/2$.
- (c) Bestäm fördelningsfunktionen för H_n .
- (d) Bestäm frekvensfunktionen för H_n . Utnyttja att $f(k) = F(k) - F(k-1)$ för heltalsvärda stokastiska variabler.
- (e) Beräkna $E[H_{2^i}]$, $i = 1, 2, \dots, 7$. Ser du något mönster? Utnyttja detta för att motivera att $E[H_n] = O(\log_2 n)$. (Låt $n = 2^i$ så att $i = \log_2 n$.) Ett explicit uttryck för $E[H_n]$ för godtyckligt n finns inte. Se dock gärna Theorem 1 på <http://math.sun.ac.za/prodinger/postscriptfiles/florenz.ps>, där ett asymptotiskt uttryck är givet.

5. Tidsåtgång för sökning i listan (frivillig)

- (a) Följande är lite trassligt. Rita en bild så blir det nog lättare.
Antag att vi letar efter talet b , och att det vid "framåtscanningen" på nivå $i + 1$ visat sig att största tal $\leq b$ är a och minsta tal $\geq b$ är c . Hur många steg framåt behöver vi då ta på nivå i ? Jo, vi måste gå igenom alla noder på nivå i med tal mellan a och c . (Om talet b eller något tal mellan b och c finns på nivå i , så blir det någon/några noder färre, men det behöver vi inte bry oss om.) Dessa noder är alltså sådana att de finns på nivå i men ej på nivå $i + 1$. Det betyder att för varje sådan nod har det blivit klave i slantsinglingen. Vad är då det förväntade antalet steg man behöver ta på nivå i (med andra ord förväntat antal klave innan det blir krona för första gången)?

(b) Argumentera med hjälp av 3(c) och 4(a) ovan för att den förväntade tidsåtgången vid sökning asymptotiskt är $O(\log_2 n)$.

Tidsåtgången för insättningen och borttagning av tal är av samma storleksordning, men det går vi ej närmre in på här.

Sista inlämningsdag 7/11.