

ΕΠΙΛΟΓΗ (selection)

Το πρόβλημα της επιλογής

Δίνεται μια ακολουθία S από n στοιχεία και ένας ακέραιος k , όπου $1 \leq k \leq n$. Να προσδιοριστεί το k μικρότερο στοιχείο της S .

Δεν έχουμε ταξινομημένους αριθμούς

Υπόθεση: Η αναίτητη του παράλληλου αλγόριθμου θα γίνει για το SM SIMD μοντέλο.

Ορισμός: Τα στοιχεία ενός συνόλου A ικανοποιούν μια γραμμική διάταξη $<$ τότε και μόνο τότε αν

(i) για $a, b \in A$, $a < b$, $a = b$ ή $b < a$

και
(ii) για $a, b, c \in A$, αν $a < b$ και $b < c$, τότε $a < c$.

Παράδειγμα: Το σύνολο των ακεραίων ακέραιων ικανοποιεί μια γραμμική διάταξη.

Βαθμός Για μια ακολουθία $S = \{s_1, s_2, \dots, s_n\}$ της οποίας τα στοιχεία είναι και στοιχεία ενός συνόλου με γραμμική διάταξη, ο

βαθμός ενός στοιχείου s_i του S είναι το πλήθος των στοιχείων του S που προηγούνται του s_i συν 1.

Παράδειγμα: $S = \{9, -4, 3, -6, 7, 0\}$ ο βαθμός του 0 είναι 3.

Εξήγηση: Μικρότερα στοιχεία του 0 είναι τα -4, -6, δηλ. πλήθος=2 \rightarrow βαθμός του 0=3

Αν $s_i = s_j$ τότε το s_i προηγείται του s_j τότε και μόνον τότε αν $i < j$.

Επιλογή

Δίνεται μια ακολουθία $S = \{s_1, s_2, \dots, s_m\}$, της οποίας τα στοιχεία έχουν παρθεί από ένα γραμμικά διατεταγμένο σύνολο, και ένας ακέραιος k , $1 \leq k \leq m$. Ζητείται ο βαθμός του στοιχείου της S με βαθμό k . Το στοιχείο με βαθμό k θα συμβολίζεται με $s(k)$.

Πομπητικότητα (κλίτη όρο)

Αν τα στοιχεία του S ήταν ταξινομημένα s_{m1}, \dots, s_{m2} .

$$S = \{s_{(1)}, s_{(2)}, \dots, s_{(m)}\}$$

τότε το $s(k)$ θα βγαίνει σε ένα βήμα. Προφανώς δεν υποθέτουμε ότι έχουμε αλυσή

των περιπτώσεων ούτε επιθυμούμε να ταξινομήσουμε τα στοιχεία του S .

Αν $k=1$ ή $k=n$, τότε εξετάζοντας όλα τα στοιχεία της S διατηρώντας κάθε φορά το μικρότερο ($k=1$) (ή το μεγαλύτερο ($k=n$)) βρίσκεται το ζητούμενο στοιχείο. Ωστόσο αυτός ο αλγόριθμος δεν μπορεί να εφαρμοστεί αν $1 < k < n$. Στην καλύτερη περίπτωση χρόνος n πολλαπλασιάζεται του αλγόριθμου είναι

$\Omega(n)$ (κρίσιμ όριο)

Ένας ακολουθιακός αλγόριθμος

-> στην καλύτερη περίπτωση έχει πολυπλοκότητα=1

Χαρακτηριστικά


- αναδρομικός αλγόριθμος
- διαιρεί και βασίζεται (divide and conquer)
- αναρρέει ένα ημίμοιο στοιχείων σε κάθε φάση

Procedure SEQUENTIAL SELECT (S, k)

- Βήμα 1:** αν $|S| \leq Q$ τότε ταξινόμησε την S και επέστρεψε το $k^{\text{στο}}$ στοιχείο
αλλιώς υποδιαίρεσε την S σε $|S|/Q$ υποακολουθίες με Q στοιχεία η κάθε μία (μέχρι $Q-1$ εναπομείναντα
στοιχεία)
Τέλος αν.
- Βήμα 2:** Ταξινόμησε κάθε υποακολουθία και υπολόγισε το μέσο της.
- Βήμα 3:** Κάλεσε την SEQUENTIAL SELECT αναδρομικά για τον υπολογισμό του m , το μέσο των $|S|/Q$ μέσων
που βρέθηκαν στο βήμα 2.
- Βήμα 4:** Δημιούργησε τρεις υποακολουθίες $S_1, S_2,$ και S_3 με στοιχεία της S μικρότερα, ίσα, και μεγαλύτερα από
το m , αντίστοιχα.
- Βήμα 5:** αν $|S_1| \geq k$ τότε {το $k^{\text{στο}}$ στοιχείο της S πρέπει να είναι στο S_1 }
κάλεσε την SEQUENTIAL SELECT αναδρομικά για να βρείς το $k^{\text{στο}}$ στοιχείο του S_1
αλλιώς αν $|S_1| + |S_2| \geq k$ τότε επέστρεψε m {διότι το k στοιχείο ανήκει στο S_2 }
αλλιώς κάλεσε την SEQUENTIAL SELECT αναδρομικά για να βρείς το $(k - |S_1| - |S_2|)^{\text{στο}}$ στοιχείο του
 S_3 {διότι το k στοιχείο ανήκει στο S_3 }.
τέλος αν.
τέλος αν.

• divide and conquer

Βήμα 5



Εξήγηση Βήματος 5: Αφού το m είναι μέσο των $|S|/Q$ στοιχείων, υπάρχουν $|S|/2Q$ στοιχεία $\geq m$
 Κάθε ένα από τα $|S|/Q$ στοιχεία ήταν το ίδιο μέσο ενός συνόλου Q στοιχείων, δηλ. υπάρχουν $Q/2$ στοιχεία \geq από αυτό.
 Άρα υπάρχουν $(|S|/2Q) \times (Q/2) = |S|/4$ στοιχεία του S τα οποία είναι σίγουρα $\geq m$




Figure 2.1 Main idea behind procedure SEQUENTIAL SELECT.

Ανάλυση Πολυσημοκόμενου

Βήμα 1: Ταξινόμηση της S είναι $|S| \leq Q$ απαιτεί βραδύ χρόνο $O(1)$. Διαφορετικά, υποδιαιρέση της S απαιτεί $c_1 n$ χρόνο

Βήμα 2: Η ταξινόμηση κέρει $|S|/Q$ υποακολουθίας (έχει Q στοιχεία) απαιτεί βραδύ χρόνο. Για όλη $c_2 n$ χρόνο

Βήμα 3: $t(n/Q)$, $t(n)$: χρόνος εκτέλεσης της SEQUENTIAL SELECT

Βήμα 4: $c_3 n$

Βήμα 5: $(|S|/2Q) \times (Q/2) = |S|/4$ στοιχεία της S (πλέον στοιχεία) είναι μεγαλύτερα ή ίσα με m . Συνεπώς $|S_1| \leq 3|S|/4$. Όμοια $|S_2| \leq 3|S|/4$. Συνεπώς μια αναδρομική κλήση της SEQUENTIAL SELECT απαιτεί $t(3n/4)$ χρόνο.

Συνοψικά: $t(n) = c_4 n + t(n/Q) + t(3n/4)$

όπου

$$c_4 = c_1 + c_2 + c_3$$

Αλγόριθμος του Q

Αν το Q επιλεγεί τέτοιο ώστε

$$u/Q + 3u/4 \leq u$$

τότε οι δυο αναδρομικές κλήσεις στην procedure εφαρμόζονται σε φθίνουσα ακολουθία. Οποιαδήποτε τιμή του $Q \geq 5$ ικανοποιεί την ανωτέρω συνθήκη. Για $Q=5$ έχουμε

$$T(n) = C_4 n + T(n/5) + T(3n/4)$$

Υποθέτουμε

$$T(n) \leq C_5 n$$

έχουμε

$$T(n) \leq C_4 n + C_5 (19n/20)$$

και για $C_5 = 20C_4$

$$\begin{aligned} T(n) &\leq C_5 (n/20) + C_5 (19n/20) \\ &= C_5 n \end{aligned}$$

$$T(n) = O(n)$$

βέλτιστος
χρόνος!

ΔΥΟ ΧΡΗΣΙΜΟΙ ΑΠΟΡΙΘΜΟΙ

ΣΤΟ ΕΡΕΩ SM SIMB ΜΟΝΤΕΛΟ ΔΕΝ ΜΠΟΡΟΥΝ
ΔΥΟ ΕΠΕΞΕΡΓΑΣΤΕΣ ΝΑ ΠΡΟΒΛΕΨΑΪΟΥΝ ΤΗΝ
ΙΔΙΑ ΤΟΠΟΘΕΣΙΑ ΗΜΕΡΗΣ ΤΟΥ ΧΡΟΝΟΥ.

ΜΕΤΑΔΟΣΗ (broadcasting)

(i) Όσο οι επεξεργαστές χρειάζονται να δια-
βήθουν ένα δεδομένο ~~data~~ μια συγκεκριμέ-
νη τοποθεσία της κοινής ημερίδας.

ΕΠΙΚΟΙΝΩΝΙΑ (όχι με ένα)

(ii) Κάθε επεξεργαστής πρέπει να ^{κάνει} υπολογισμούς
για δεδομένα, τα οποία υπο-
κουν στους άλλους επεξεργαστές και
συνεπώς χρειάζεται να ληφεί υπόψη τα
δεδομένα.

Οι δύο αυτές λειτουργίες δεν μπορούν να
εκτελεστούν σε ένα βήμα στο ΕΡΕΩ
μοντέλο και πρέπει να προομοιωθούν.

Υπόθεση: N επεξεργαστές P_1, P_2, \dots, P_N
είναι διατεταγμένοι σε ένα ΕΡΕΩ SM
SIMB υπολογιστή.

D: Είναι η τοποθεσία της μνήμης στην οποία υπάρχει το ζητούμενο δεδομένο. Αυτή τη μνήμη θα προσπελάσουν όλοι οι επεξεργαστές προκειμένου να διαβάσουν το δεδομένο
A: πίνακας αποθηκευμένος στη μνήμη μήκους N. Είναι αρχικά άδειος και χρησιμοποιείται από την συνάρτηση σαν "χώρος εργασίας" για τον διαμοιρασμό των στοιχείων της D στους επεξεργαστές. Η i-θέση του πίνακα αυτού συμβολίζεται με A(i).

$O(\log N)$

Procedure BROADCAST (D, N, A)

Βήμα 1: Ο επεξεργαστής P_1

- (i) διαβάζει την τιμή από την D,
- (ii) την αποθηκεύει στην μνήμη του, και
- (iii) τη γράφει στην A(1).

Βήμα 2: για $i=0$ μέχρι $(\log N-1)$ κάνε

για $j=2^i+1$ μέχρι 2^{i+1} κάνε παράλληλα

Ο επεξεργαστής P_j


- (i) διαβάζει την τιμή από την A($j-2^i$),
- (ii) την αποθηκεύει στην μνήμη του, και
- (iii) τη γράφει στην A(j).

τέλος για

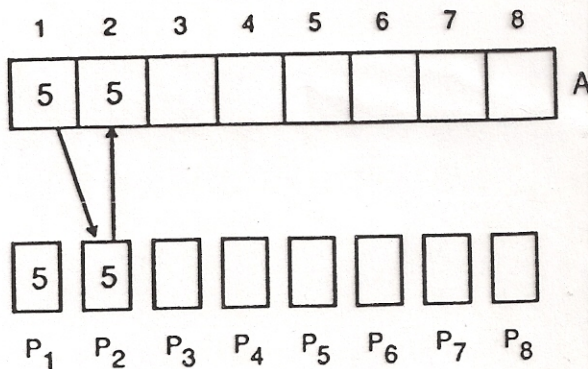
τέλος για.

Τρόπος λειτουργίας της BROADCAST για $N=8, D=5$:

Όταν η διαδικασία σταματάει τότε όλοι οι επεξεργαστές έχουν αποθηκευμένο το D στην τοπική τους μνήμη για μετέπειτα χρήση. Αφού ο αριθμός των επεξεργαστών που έχουν διαβάσει τη D διπλασιάζεται σε κάθε επανάληψη, η διαδικασία τερματίζει σε χρόνο $O(\log N)$. Οι απαιτήσεις της μνήμης για την BROADCAST είναι ένας πίνακας μήκους N .




(a)




(b) ($i=0$)

δεν χρειάζεται



(c) ($i=1$)

$O(\log N)$ χρόνο
 $N/2$ μνήμη



(d) ($i=2$)

Υπολογισμός των αθροισμάτων
Υποθέτουμε: P_i έχει το a_i στην τοπική μνήμη.
 $P_i := a_1 + a_2 + \dots + a_i$

procedure ALLSUMS (a_1, a_2, \dots, a_N)

for $j=0$ to $\log N - 1$ do

for $i=2^j+1$ to N do in parallel

Processor P_i

(i) obtains a_{i-2^j} from P_{i-2^j} through shared memory and

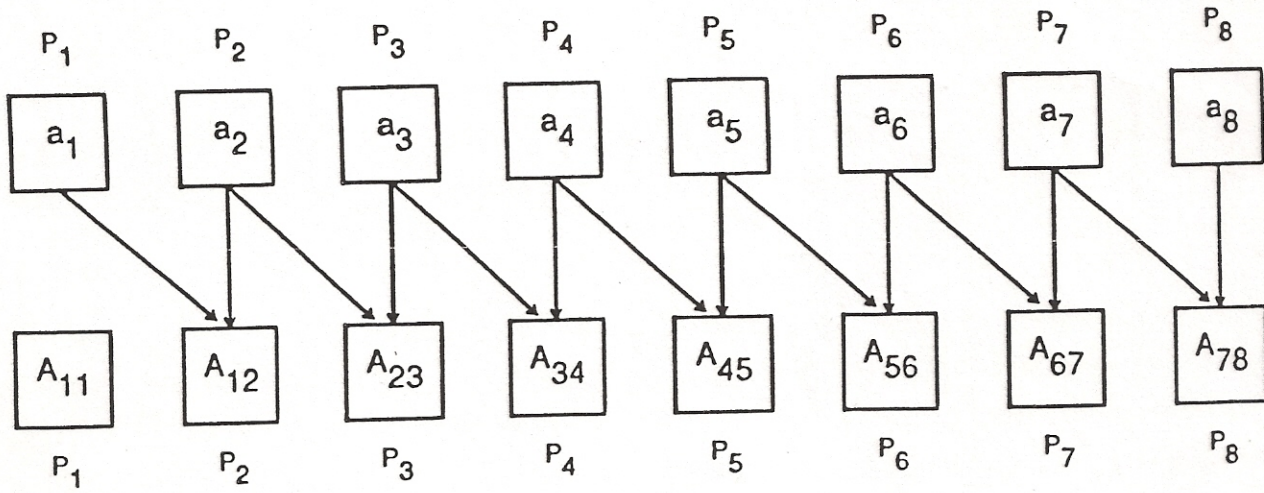
(ii) replaces a_i with $a_{i-2^j} + a_i$.

end for

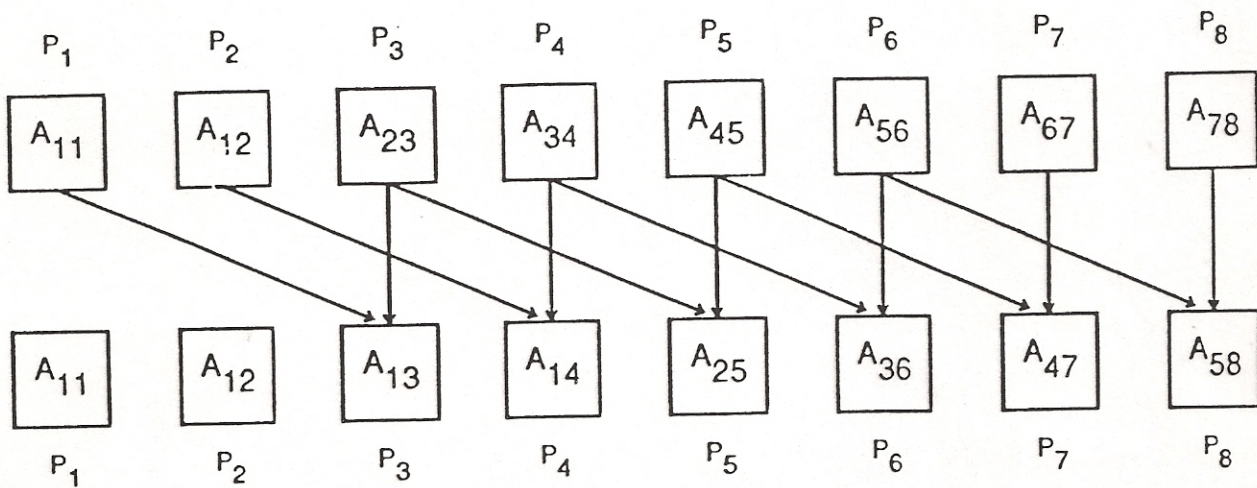
end for. \square

$$A_{ij} = a_i + a_{i+1} + \dots + a_j$$

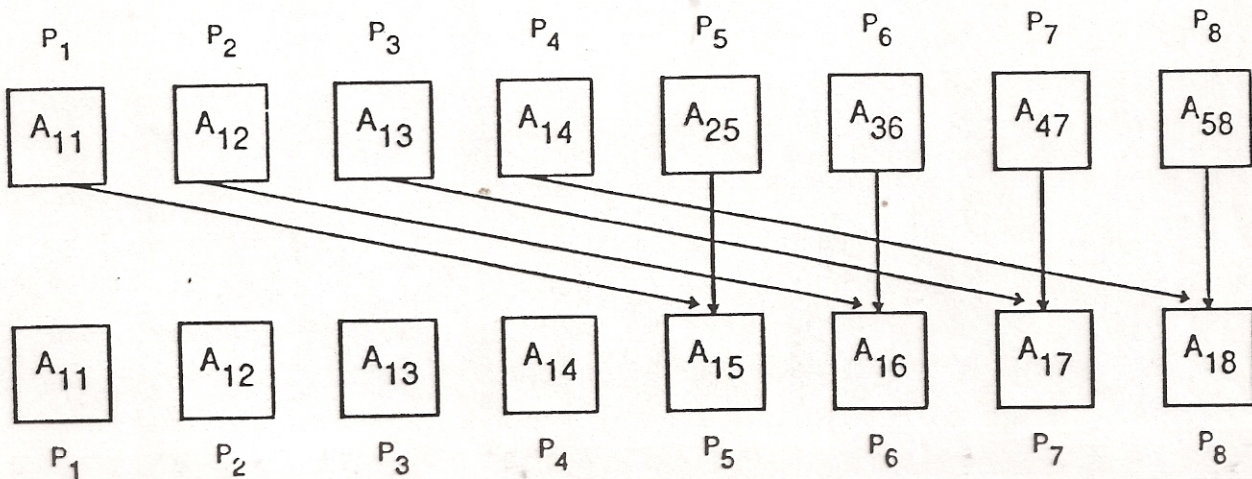
$$O(\log N)$$



(a) $j = 0$



(b) $j = 1$



(c) $j = 2$

όταν έχει ολοκληρωθεί η διαδικασία, το a_i έχει αντικατασταθεί από το P_i για $1 \leq i \leq N$. Η διαδικασία απαιτεί $O(\log N)$ χρόνο αφού ο αριθμός των επεξεργασιών έχει τελειώσει τους υπολογισμούς σε κάθε βήμα.

ΕΝΑΣ ΑΛΓΟΡΙΘΜΟΣ ΓΙΑ ΤΗΝ ΠΑΡΑΛΛΗΛΗ ΕΠΙΛΟΓΗ (EREW SM SIMD)

ΥΠΟΘΕΣΕΙΣ:

1. $S = \{s_1, s_2, \dots, s_n\}$, k , $1 \leq k \leq n$
2. P_1, P_2, \dots, P_n ανεξαρτητές
3. Κάθε ανεξαρτητής έχει γάβι το n
και έχει υποστηρίξει το k από την
 $N = n^{1-k}$, όπου $0 < k < 1$.
4. Κάθε ένας από τους n^{1-k} ανεξαρτητές
μπορεί να διασπαστεί σε n^k στοιχεία
στην τομική μνήμη του
5. Κάθε ανεξαρτητής μπορεί να εκτελέσει
τις SEQUENTIAL SELECT, BROADCAST,
και ALLSUMS.
6. M είναι ένας μονοδιάστατος πίνακας
στην κοινή μνήμη μήκους N .

Procedure PARALLEL SELECT (S, k)

Βήμα 1: αν $|S| \leq 4$ τότε ο P_1 χρησιμοποιεί το πολύ πέντε συγκρίσεις για να επιστρέψει το $k^{\text{στο}}$ στοιχείο αλλιώς

(i) Η ακολουθία S υποδιαιρείται σε $|S|^{1-x}$ υποακολουθίες S_i μήκους $|S|^x$ η κάθε μία, όπου $1 \leq i \leq |S|^{1-x}$

(ii) Η υποακολουθία S_i ανατίθεται στον επεξεργαστή P_i .

τέλος αν.

Βήμα 2: για $i=1$ μέχρι $|S|^{1-x}$ κάνε παράλληλα

(2.1) {Ο P_i αποκτά το μέσο m_i , δηλ., το $\lceil |S_i|/2 \rceil$ ισοστό στοιχείο, της υποακολουθίας του }
SEQUENTIAL SELECT ($S_i, \lceil |S_i|/2 \rceil$)

(2.2) Ο P_i αποθηκεύει το m_i στο $M(i)$
τέλος για.

Βήμα 3: {Το υποπρόγραμμα καλείται αναδρομικά για να αποκτηθεί το μέσο m του M }
PARALLEL SELECT ($M, \lceil |M|/2 \rceil$).

Βήμα 4: Η ακολουθία S υποδιαιρείται σε τρία υποακολουθίες:

$L = \{s_i \in S: s_i < m\}$,

$E = \{s_i \in S: s_i = m\}$, και

$G = \{s_i \in S: s_i > m\}$.

Βήμα 5: αν $|L| \geq k$ τότε PARALLEL SELECT (L, k)

αλλιώς αν $|L| + |E| \geq k$ τότε επέστρεψε m

αλλιώς PARALLEL SELECT ($G, k - |L| - |E|$)

τέλος αν

τέλος αν.

Ανάγνωση

Βήμα 1: Για την εκτέλεση του βήματος αυτού απαιτείται η διεύθυνση αρχής A της ακολουθίας S στην κοινή μνήμη, το μέγεθος $|S|$ και η τιμή k . Οι τιμές αυτές, μεταδίδονται σε όρους τους επηρεαζόμενοι με την BROADCAST σε $O(\log n^{1-x})$ χρόνο. Αν $|S| \leq k$, τότε ο P_1 επιβεβαιώνει το k -στό στοιχείο σε σταθερό χρόνο. Διαφορετικά ο P_1 υπολογίζει τη διεύθυνση του πρώτου και του τελευταίου στοιχείου της S_i από τους

$$A + (i-1)n^x \text{ και } A + in^x - 1$$

σε σταθερό χρόνο. Συνολικά το βήμα 1 απαιτεί $c_1 \log n$ μονάδες χρόνου για κάποια σταθερά c_1 .

Βήμα 2: Η SEQUENTIAL SELECT βγαίνει το μέσο μιας ακολουθίας μήκους n^x σε $c_2 n^x$ μονάδες χρόνου για κάποια σταθερά c_2 .

Βήμα 3: Κρατείται η PARALLEL SELECT
για μια ακολουθία μήκους n^{1-x} . Συνε-
πώς το παρόν βήμα απαιτεί $t(n^{1-x})$ χρό-
νο.

Βήμα 4: Η ακολουθία S χωρίζεται στις υπο-
ακολουθίες L , E και Θ ως εξής:

(i) Το m μεταδίδεται σε όλους τους ελε-
γερματούς σε $O(\log n^{1-x})$ χρόνο με τη
χρήση της BROADCAST.


(ii) Κάθε ελεγχερματούς P_i χωρίζει την S_i
σε τρεις υποακολουθίες L_i , E_i και Θ_i
με στοιχεία μικρότερα, ίσα και μεγαλύτε-
ρα από το m , αντίστοιχα. Αυτή η
εργασία μπορεί να γίνει σε χρόνο ασυμ-
πτικό ως προς το μέγεθος της S_i , δη-
λαδή σε $O(n^x)$ χρόνο.

(iii) Οι υποακολουθίες L_i , E_i και Θ_i συλ-
λώνονται για να διακριθούν τις L , E
και Θ . Στη συνέχεια δείχνεται πως
αυτή η εργασία μπορεί να γίνει για

των L_i . Όμοια και με τον ίδιο τρόπο
 πρέπει να γίνει για τη ενδιάμεση των E_i
 και G_i , αντίστοιχα. Θέτουμε $a_i = |L_i|$,
 υπολογίζουμε το άθροισμα

$$z_i = \sum_{j=1}^i a_j, \quad 1 \leq i \leq n^{1-x}$$

Τα αποτελέσματα αυτά υπολογίζονται σε
 $O(\log n^{1-x})$ χρόνο από τους n^{1-x} επεξεργα-
 στές. χρησιμοποιώντας την ALSUMS.
 Οι επεξεργαστές συγχωρούν τις L_i
 υποακολουθίες τους για τον σχηματισμό της
 L .



$$z_1 = a_1 = |L_1|, \quad z_2 = a_1 + a_2 = |L_1| + |L_2|$$

Σχηματισμός της L

Η επεξεργασία P_i αναφέρεται στην L_i της L
 ξεκινώντας από τη θέση $z_{i-1} + 1$ (με $z_0 = 0$). Η επεξεργασία
 αυτή πρέπει να γίνει σε $O(n^x)$ χρόνο.
 Συνεπώς ο χρόνος που απαιτείται για το
 μαζόν βήμα είναι $O(n^x)$ για κάποια στα-
 θερά c_3 .

Βήμα 5 Το μέγεθος των L που χρειάζονται

στο βήμα αυτό έχει υπολογιστεί στο βήμα 4 και είναι $\approx n^{1-x}$. Η ίδια παρατήρηση ισχύει για τα μεγέθη των E και G .

Στη συνέχεια πρέπει να υπολογιστεί ο χρόνος που απαιτείται για κάθε μία από τις δύο αναδρομικές κλήσεις της PARALLEL SELECT.

Επειδή το m είναι το μέσο του M , έπεται ότι $n^{1-x}/2$ στοιχεία είναι μεγαλύτερα από αυτό. Επίσης κάθε στοιχείο του M είναι μικρότερο από $n^x/2$ τουλάχιστον στοιχεία της S .

Αρα $\frac{n^{1-x}}{2} \cdot \frac{n^x}{2} = \frac{n^{1-x+x}}{4}$ είναι τουλάχιστον

μεγαλύτερα ή ίσα του m . Συνεπώς $|L| \leq \frac{3n}{4}$. Όμοια, $|G| \leq \frac{3n}{4}$. Τελικά, το παρόν βήμα απαιτεί το ποσό $t(3n/4)$ χρόνο.

Η προκύπτουσα αναδρομή έχει σαν αναδρομικές την ακόλουθη αναδρομική επίλυση για το συνολικό χρόνο

$$t(n) = c_1 \log n + c_2 n^x + t(n^{1-x}) + c_3 n^x + t(3n/4)$$

της οποίας η λύση είναι $t(n) = O(n^x)$ για

$n > 4$. Επίσης $\epsilon(n) = p(n) \cdot t(n) = n^{1-x} \cdot O(n^x) = O(n)$. Το κόστος αυτό είναι βεβαίως $\Omega(n)$.

Παράδειγμα

$$S = \{3, 14, 16, 20, 8, 31, 22, 12, 33, 1, 4, 9, 10, 5, 13, 7, 24, 2, 14, 26, 18, 34, 36, 25, 14, 27, 32, 35, 33\}$$

$$n = 29, \quad k = 21, \quad N = 5. \quad \text{Συνεπώς}$$

$$|S|^{1-x} = 5 \quad \text{ή} \quad 29^{1-x} = 5 \quad \text{ή} \quad 1-x = 0.47796$$

Επίσης 2.4 (d) $|L| = 11, \quad |E| = 3, \quad |L| + |E| < k$ αναδρομικά

κλήση με $S = G$ και $k = 21 - (11 + 3) = 7$.

Επιπλέον $|G| = 15$ χρησιμοποιώντας $15^{1-x} = 3.6485$ δηλ. 3 επιπλέον κλήσεις

Σχήμα 2.4 (g)

Επιπλέον $|L| = 6, \quad |E| = 1, \quad |L| + |E| = 7 = k$

και $m = 26$

- $p(n) < n^{1/2}$, προαρκουστικός
- $t(n)$ μικρό, προαρκουστικό
- $c(n) = p(n) \times t(n)$ βέλτιστο κόστος όταν $c(n) = \Omega(n)$ του ακολουθιακού αλγορίθμου

S

3	14	16	20	8	31	22	12	33	1	4	9	10	5	13	7	24	2	14	26	18	34	36	25	14	27	32	35	33
---	----	----	----	---	----	----	----	----	---	---	---	----	---	----	---	----	---	----	----	----	----	----	----	----	----	----	----	----

(a)

P_1

P_2

P_3

P_4

P_5

3	14	16	20	8	31
---	----	----	----	---	----

22	12	33	1	4	9
----	----	----	---	---	---

10	5	13	7	24	2
----	---	----	---	----	---

14	26	18	34	36	25
----	----	----	----	----	----


14	27	32	35	33
----	----	----	----	----

(b)

M

14	9	7	25	32
----	---	---	----	----

(c)



(d)

16	20	31	22	33
----	----	----	----	----

24	26	18	34	36
----	----	----	----	----


25	27	32	35	33
----	----	----	----	----

(e)

M

22	26	32
----	----	----

(f)



(g)