

Κινητός και Διάχυτος Υπολογισμός (Mobile & Pervasive Computing)

Δημήτριος Κατσαρός, Ph.D.

Χειμώνας 2005

Διάλεξη 4η


Ιστοσελίδα του μαθήματος

- http://skyblue.csd.auth.gr/~dimitris/courses/mpc_fall05.htm
- Θα τοποθετούνται οι διαφάνειες του επόμενου μαθήματος
- Σταδιακά θα τοποθετηθούν και τα research papers που αντιστοιχούν σε κάθε διάλεξη


Περιεχόμενα

- **Αρχιτεκτονική κινητού δικτύου**
- Εκπομπή σε πολλαπλά κανάλια
- Caching
- Prefetching
- Ευρετήρια


Αρχιτεκτονική κινητού δικτύου



Αρχιτ. Personal Comm. Sys. (PCS)



Γενικό μοντέλο εκπομπής



Περιεχόμενα

- Αρχιτεκτονική κινητού δικτύου
- **Εκπομπή σε πολλαπλά κανάλια**
- Caching
- Prefetching
- Ευρετήρια


Πολλαπλά κανάλια εκπομπής

Για λόγους όπως:


- Application scalability
 - Μια εφαρμογή αποκτά επιπλέον κανάλια για να εξυπηρετήσει μεγαλύτερο πληθυσμό
- Fault tolerance
 - Τρεις servers εκπέμπουν σε μια γεωγραφική περιοχή σε μη συνεχόμενες συχνότητες, αλλά οι δυο παθαίνουν βλάβη και τα κανάλια τους ανατίθενται στον τρίτο
- Reconfiguration of adjoining cells
 - Γειτονικά κελιά εξυπηρετούνται από διαφορετικούς servers, αλλά τα κελιά συνενώνονται και τα κανάλια ανατίθενται στον έναν από τους δυο
- Heterogeneous clients
 - Πελάτες με ετερογενείς δυνατότητες

Είναι δυνατόν να υπάρχουν πολλαπλά κανάλια εκπομπής


Εμπομπή σε Πολλαπλά Κανάλια



Ιεραρχικά προγράμματα εκπομπής



(a) A flat broadcast program




(b) A hierarchical broadcast program with its tree representation

	Access frequency						Average expected delay	
	$P_r(R_1)$	$P_r(R_2)$	$P_r(R_3)$	$P_r(R_4)$	$P_r(R_5)$	$P_r(R_6)$	in figure 1(a)	in figure 1(b)
Case 1	0.167	0.167	0.167	0.167	0.167	0.167	1	1.16
Case 2	0.25	0.25	0.125	0.125	0.125	0.125	1	1
Case 3	0.3	0.3	0.1	0.1	0.1	0.1	1	0.9
Case 4	0.4	0.4	0.05	0.05	0.05	0.05	1	0.7

Μέση καθυστέρηση σε ένα κανάλι

Request for data item x



Μέση καθυστέρηση για
κάθε αντικείμενο στο
κανάλι i είναι:

$$\sum_{x=1}^{N_i} (N_i - x) / N_i$$

Δημιουργία ιεραρχικών προγραμμ.


Property 2. Let $t_i = \sum_{h=1}^i N_h$ and $t_0 = 0$. Then, N_i data items, denoted by R_j , $t_{i-1} + 1 \leq j \leq t_i$, are allocated to broadcast disk i , and $d_i = d_{R_j}$ for $j \in [t_{i-1} + 1, t_i]$.

Πρόβλημα
Δημιουργίας
Ιεραρχικού
Προγράμματος
Εκπομπής

$$\begin{aligned} & \sum_{j=1}^n d_{R_j} \cdot P_r(R_j) \\ &= \sum_{i=1}^K d_i \sum_{j=t_{i-1}+1}^{t_i} P_r(R_j) \\ &= \sum_{i=1}^K \left(\sum_{q=1}^{N_i} \frac{N_i - q}{N_i} \right) \sum_{j=t_{i-1}+1}^{t_i} P_r(R_j), \end{aligned}$$

where $t_i = \sum_{h=1}^i N_h$ and $t_0 = 0$.

Δενδρική αναπαράσταση



Κόστος επιπέδου του δένδρου

Definition 1. Suppose that level v in the allocation tree has $j - i + 1$ data nodes, $R_i, R_{i+1}, \dots, R_j$. The cost of level v is defined as

$$C_{i,j} = \sum_{k=1}^{j-i+1} \frac{(j-i+1) - k}{j-i+1} \sum_{q=i}^j P_r(R_q),$$

which is equal to $w_v \cdot P_{L_v}$, where w_v and P_{L_v} are, respectively, the weight of leaf nodes and the aggregate access frequency for the leaf nodes in level v of the allocation tree.

Definition 2. Suppose that node R has $j - i + 1$ child data nodes, $R_i, R_{i+1}, \dots, R_j$, which are sorted according to the descending order of $P_r(R_q)$, $i \leq q \leq j$, i.e., $P_r(R_q) \geq P_r(R_y)$ iff $q \leq y$. The reduction gain achieved by grouping nodes $R_{p+1}, R_{p+2}, \dots, R_j$ and attaching them under a new child node, denoted by $\delta(p)$, can be formulated as $\delta(p) = C_{i,j} - (C_{i,p} + C_{p+1,j})$.

Αλγόριθμος VF^K

Input. Assume that $R_1, \dots, R_n$ have been sorted according to the descending order of $P_r(R_j)$, $1 \leq j \leq n$, i.e., $P_r(R_q) \geq P_r(R_y)$ iff $q \leq y$. K is the number of broadcast disks in a broadcast disk array.

Output. The resulting allocation tree.

begin

1. Create table AT with K rows;
2. $AT(1).B = 1$; /* $AT(1).B$ records the beginning of level 1 */
3. $AT(1).E = n$; /* $AT(1).E$ records the end of level 1 */
4. $AT(1).LC = C_{1,n}$; /* $AT(1).LC$ records the cost of level 1 */
5. **for** each row i in table AT and $i \geq 2$
6. **begin**
7. $AT(i).B = 0$; /* $AT(i).B$ records the beginning of level i */
8. $AT(i).E = 0$; /* $AT(i).E$ records the end of level i */
9. $AT(i).LC = 0$; /* $AT(i).LC$ records the cost of level i */
10. **end**
11. $pivot = 1$;

Αλγόριθμος VFK

```

12. repeat
13.   begin
14.     Choose row  $i$  from table  $AT$  such that  $AT(i).LC$  is maximal
        among all unmarked rows;
15.     if ( $i == 1$  or  $i == pivot$ ) /* Upward and downward partition */
16.       begin
17.          $j = Partition(R_{AT(i).B}, R_{AT(i).B+1}, \dots, R_{AT(i).E})$ ;
18.         {Update table  $AT$  accordingly and unmark all rows;
19.          $pivot++$ ;}
20.       end
21.     else /* Middle partition */
22.       begin
23.          $j = Partition(R_{AT(i).B}, R_{AT(i).B+1}, \dots, R_{AT(i).E})$ ;
24.         if ( $AT(i-1).E - AT(i-1).B < (j - AT(i).B)$ )
25.           {Update table  $AT$  accordingly and unmark all rows;
26.            $pivot++$ ;}
27.         else {
28.           Mark row  $i$ ;
29.           Merge ( $R_{AT(i).B}, R_{AT(i).B+1}, \dots, R_j$ ) and
              ( $R_{j+1}, R_{j+2}, \dots, R_{AT(i).E}$ ) together;}
30.         end
31.       end
32.   until ( $pivot == K$ )
end

```

Αλγόριθμος VF^K



Procedure *Partition*($R_i, R_{i+1}, \dots, R_j$).

1. Determine p^* such that


$$\delta(p^*) = \max_{\forall p \in \{i, i+(j-i+1)/2-1\}} \{\delta(p)\}.$$

2. Attach nodes $R_{p^*+1}, R_{p^*+2}, \dots, R_j$ under a new node I in the tree.
3. Return p^* .


Αλγόριθμος VF^K



Αλγόριθμος VF^K



Αλγόριθμος VF^K




Παράδειγμα του VF^K

Data record	R_1	R_2	R_3	R_4	R_5	R_6	R_7	R_8	R_9	R_{10}	R_{11}
$P_r(R_i)$	0.237	0.211	0.132	0.132	0.08	0.05	0.05	0.027	0.027	0.027	0.027

(a) Partition $(R_1, R_2, \dots, R_{11})$ is selected and decomposed to $(R_1, \dots, R_4)$ and $(R_5, \dots, R_{11})$.

Level i	$AT(i).B$	$AT(i).E$	$AT(i).LC$
1	1	11	5*
2	0	0	0
3	0	0	0
4	0	0	0

p	1	2	3	4	5
$C_{1,11}$	5	5	5	5	5
$C_{1,p} + C_{p+1,11}$	3.4335	2.484	2.05	1.932	2.104
$\delta(p)$	1.5665	2.516	2.95	3.068*	2.896




Παράδειγμα του VF^K

(b) Partition $(R_1, R_2, \dots, R_4)$ is selected and decomposed to (R_1, R_2) and (R_3, R_4) .

Level i	$AT(i).B$	$AT(i).E$	$AT(i).LC$
1	1	4	1.068*
2	5	11	0.864
3	0	0	0
4	0	0	0

p	1	2
$C_{1,4}$	1.068	1.068
$C_{1,p} + C_{p+1,4}$	0.475	0.356
$\delta(p)$	0.593	0.712*




Παράδειγμα του VF^K

(c) Partition $(R_5, R_6, \dots, R_{11})$ is selected and decomposed to $(R_5, \dots, R_7)$ and $(R_8, \dots, R_{11})$.

Level	$AT(i).B$	$AT(i).E$	$AT(i).LC$
1	1	2	0.224
2	3	4	0.132
3	5	11	0.864*
4	0	0	0


p	5	6	7
$C_{5,11}$	0.864	0.864	0.864
$C_{5,p} + C_{p+1,11}$	0.52	0.381	0.342
$\delta(p)$	0.344	0.483	0.522*



Παράδειγμα του VF^K

(d) The final result of table AT .

Level i	$AT(i).B$	$AT(i).E$	$AT(i).LC$
1	1	2	0.224
2	3	4	0.132
3	5	7	0.18
4	8	11	0.162



Το πρόβλημα Windows Scheduling

- Έστωσαν **h slotted κανάλια** και **n αντικείμενα (σελίδες)**, που στην κάθε μια αντιστοιχεί **ένα παράθυρο (window) $w_i \geq 1$** , όπου w_i είναι ακέραιος.
- Είναι δυνατό να εκπέμψουμε τις n σελίδες στα h κανάλια, μια σελίδα σε κάθε κανάλι σε κάθε slot (χρονική στιγμή), ώστε *το κενό μεταξύ δυο συνεχόμενων εμφανίσεων της σελίδας i να είναι όχι μεγαλύτερο από w_i* ?
- Εάν για δεδομένο h και $W(w_1, w_2, \dots, w_n)$, η απάντηση στο παραπάνω ερώτημα είναι καταφατική, το πρόγραμμα εκπομπής που λύνει το πρόβλημα αποκαλείται **$\langle h, W \rangle$ -πρόγραμμα**
- Το πρόβλημα βελτιστοποίησης είναι να βρούμε το ελάχιστο h που θα το σημειώνουμε ως $H(W)$, ώστε να υπάρχει το **$\langle h, W \rangle$ -πρόγραμμα**
- Το πρόβλημα αυτό αποκαλείται **optimal windows scheduling πρόβλημα**

Το πρόβλημα Windows Scheduling

- Το πρόβλημα αυτό ανήκει στην κλάση των NP-Hard ακόμα και στην περίπτωση που $h=1$.
- Παράδειγμα:
 - $W = \langle 2, 4, 5 \rangle$
 - $\langle 1, W \rangle = [2 \ 4 \ 2 \ 5 \ 2 \ 4 \ 2 \ 5]$
 - Σημειώστε ότι η πρώτη σελίδα εμφανίζεται κάθε 2 slots, η δεύτερη κάθε 4 slots και η Τρίτη κάθε 4(<5) slots


Περιεχόμενα

- Αρχιτεκτονική κινητού δικτύου
- Εκπομπή σε πολλαπλά κανάλια
- **Caching**
- Prefetching
- Ευρετήρια


Caching στους κινητούς πελάτες

- Προγράμματα εκπομπής
 - Βασίζονται στη μέση πιθανότητα προσπέλασης: μέσος όρος πάνω σε ΌΛΟΥΣ τους πελάτες
 - Όχι αναγκαστικά βέλτιστη για κάθε έναν πελάτη
- Πώς μπορεί κάθε πελάτης να υποβοηθήσει τον εαυτό του?
 - **Caching**: προσωρινή αποθήκευση των δεδομένων που λαμβάνει
 - Πολιτική caching: όταν εξαναγκάζεται να αντικαταστήσει κάποιο (επειδή η cache είναι πλήρης), αντικαθιστά εκείνα που είναι λιγότερο πιθανό να χρησιμεύσουν στο μέλλον

Το γενικό μοντέλο caching




Caching στους κινητούς πελάτες



- Ποια **πολιτική αντικατάστασης** (replacement strategy ή policy ή algorithm) θα πρέπει να χρησιμοποιούν οι πελάτες;


Least Recently Used (LRU)



9 Steps

LRU: Αντικατάσταση του αντικειμένου που έχει χρησιμοποιηθεί παλιότερα στο παρελθόν


Most Probable Accessed (MPA)



8 Steps

MPA: Αντικατάσταση του αντικειμένου που θα χρησιμοποιηθεί λιγότερο συχνά στο μέλλον

Probability Inv. Broadc. Frequency



5 Steps !

PIX: Αντικατάσταση του αντικειμένου με το μικρότερο P/X , όπου

- **P:** είναι η πιθανότητα προσπέλασης του αντικειμένου
- **X:** είναι η συχνότητα εκπομπής του αντικειμένου

$$PIX(A) = \frac{1}{2} / \frac{1}{2} = 1, PIX(B) = \frac{1}{3} / \frac{1}{6} = 2, PIX(C) = \frac{1}{6} / \frac{1}{6} = 1$$

Η πολιτική LIX (1/3)

- Η πολιτική PIX δεν είναι πρακτική
 - Απαιτεί τέλεια γνώση των πιθανοτήτων προσπέλασης
 - Απαιτεί σύγκριση των τιμών PIX όλων των αντικειμένων στην cache (σειριακή σάρωση των αντικειμένων)
- Ιδέα: προσέγγιση της πολιτικής PIX με έναν αλγόριθμο του τύπου LRU (δηλ., τον LIX) που λαμβάνει υπόψη του πιθανότητες προσπέλασης
- LRU (Least Recently Updated)
 - Τα Cached δεδομένα διατηρούνται σε μια λίστα
 - Εάν ένα δεδομένο προσπελαστεί μετακινείται στην κορυφή/αρχή της λίστας
 - Όταν συμβεί cache miss (απαιτείται να “κατεβεί” από το κανάλι και να μπει στην cache), το δεδομένο στο τέλος της λίστας εκδιώκεται από τη λίστα

Η πολιτική LIX (2/3)

- Χρήση τροποποιημένου LRU για κάθε δίσκο εκπομπής χωριστά
 - Ο LIX διατηρεί μια λίστα με αντικείμενα για κάθε δίσκο εκπομπής με συχνότητα f_j
 - Τα αντικείμενα μπαίνουν στη λίστα του αντίστοιχου δίσκου εκπομπής όπου ανήκουν
 - Όταν ένα αντικείμενο προσπελάζεται, τοποθετείται στην κορυφή/αρχή της λίστας
 - Μια εκτίμηση της πιθανότητας προσπέλασης p_i αναπροσαρμόζεται οποτεδήποτε το αντικείμενο d_i προσπελάζεται
 - Όταν ένα αντικείμενο d_i πρόκειται να εκδιωχτεί, υπολογίζεται μια LIX τιμή lix_i (που προσεγγίζει την RIX τιμή) για κάθε αντικείμενο στο τέλος κάθε λίστας
 - Το αντικείμενο με τη χαμηλότερη τιμή, τελικά εκδιώκεται
The data item with lowest value lix_i is evicted

Η πολιτική LIX (3/3)

Computing the access probability estimate p_i for d_i :

Initial value $p_i = 0$

If most recent access to d_i was at time t_i (initially $t_i = 0$) and t is the time of the current access then

$$p_i := \frac{c}{t - t_i} + (1 - c)p_i$$

c constant ($0 < c < 1$)

Approximation of PIX value
(d_i belongs to broadcast disk with frequency f_j)

$$\text{lix}_i = p_i / f_j$$


Παράδειγμα LIX

Δυο δίσκοι εκπομπής

$D_1 = \{A\}$, $D_2 = \{B, C, D\}$, συχνότητες $f_1 = 3$, $f_2 = 1$, $c = 1/2$

Η cache μπορεί να αποθηκεύσει 2 αντικείμενα.

p_i	1	2	3	4	5
A	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$	$\frac{1}{2}$
B	0	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$
C	0	0	0	$\frac{1}{8}$	$\frac{1}{8}$
D	0	0	0	0	0



evict: $lix_A = \frac{1}{2}/3 = 1/6$, $lix_B = \frac{1}{4}/1 = 1/4$

Περιεχόμενα

- Αρχιτεκτονική κινητού δικτύου
- Εκπομπή σε πολλαπλά κανάλια
- Caching
- **Prefetching**
- Ευρετήρια


Κίνητρο για prefetching

- Οι PIX/LIX αποθηκεύουν στην cache αντικείμενα, μόνο μετά αφού ζητηθούν
- Εναλλακτικά, ο κινητός πελάτης μπορεί να “κατεβάζει” αντικείμενα από το κανάλι, αφού ούτως ή άλλως το ακούει
- Ο στόχος είναι να ελαττώσει το χρόνο απόκρισης
- Μέθοδοι prefetching:
 - **Tag Team Caching**
 - **Ευρεστικό Prefetching**

Η έννοια του tag team caching

- Tag Team Caching – Τα αντικείμενα συνεχώς αντικαθιστούν το ένα το άλλο μέσα στην cache
- Για παράδειγμα,
 - έστωσαν δυο αντικείμενα x και y τα οποία εκπέμπονται από το κανάλι
 - Ο πελάτης caches το x όταν εκπέμπεται στο κανάλι
 - Εκδιώχνει το x και caches το y , όταν εκπέμπεται το y

Παράδειγμα tag team caching (1/2)



Αναμεν. Καθυστέρ. “Demand Driven”

- Υποθέτουμε ότι ένας πελάτης ενδιαφέρεται να προσπελάσει το x και το y $p_x = p_y = 0.5$ και ότι έχει μια cache με μια μόνο θέση
- Στο μοντέλο demand driven, κάνει cache το x και εάν χρειάζεται το y , περιμένει για το y και αντικαθιστά το x στην cache με το y
- Η αναμενόμενη καθυστέρηση σε cache miss είναι $\frac{1}{2}$ της περιστροφής του δίσκου
- Η αναμενόμενη καθυστέρηση πάνω σε όλες τις προσπελάσεις είναι
- $C_i * M_i * D_i$, όπου C είναι η πιθανότητα προσπέλασης, M είναι η πιθανότητα ενός cache miss και D είναι η αναμενόμενη καθυστέρηση εκπομπής για το αντικείμενο i
- Για τα αντικείμενα x και y , είναι ίση με: $0.5 * 0.5 * 0.5 + 0.5 * 0.5 * 0.5 = 0.25$

Αναμεν. Καθυστέρ. “Tag team caching”

- $0.5 * 0.5 * 0.25 + 0.5 * 0.5 * 0.25 = \mathbf{0.125}$, δηλαδή, το μέσο κόστος είναι το $\frac{1}{2}$ του αντίστοιχου κόστους στο σχήμα demand driven
- Γιατί? Ένα miss μπορεί να συμβεί σε οποιαδήποτε στιγμή στο μοντέλο demand driven, ενώ τα misses συμβαίνουν μόνο κατά τη διάρκεια του μισού broadcast στο tag team caching

Ευρεστικό Prefetching

- Απλό Ευρεστικό Prefetching
- Εκτελεί έναν υπολογισμό για κάθε αντικείμενο που εκπέμπεται στο κανάλι με βάση την πιθανότητα προσπέλασης P για το αντικείμενο και το ποσό του χρόνου T που θα περάσει μέχρι να εμφανιστεί ξανά η σελίδα στο κανάλι εκπομπής
- Εάν η $P * T$ τιμή των σελίδων που εκπέμπονται είναι υψηλότερες από αυτές των σελίδων στην cache, τότε εκείνες με τη χαμηλότερη τιμή $P * T$, εκδιώκεται από την cache

Ευρεστικό Prefetching

Page	Access Probability	Broadcast Frequency (per Period)	PLX Value
A	P	2	$P/2$
B	$P/2$	2	$P/4$
C	$P/2$	1	$P/2$

Table 2: Access and Frequency Values for the pt Example

Ευρεστικό Prefetching




Figure 7: pt Value vs. Time


Περιεχόμενα

- Αρχιτεκτονική κινητού δικτύου
- Εκπομπή σε πολλαπλά κανάλια
- Caching
- Prefetching
- **Ευρετήρια**

Παράμετροι ενδιαφέροντος (1/2)


- **Tuning time:** Ο χρόνος που ο κινητός πελάτης δαπανά “ακούγοντας” το κανάλι. Προσδιορίζει την κατανάλωση ενέργειας για την απόκτηση των δεδομένων
- **Latency (Access time):** Ο χρόνος που περνάει (κατά μέσο όρο) από τη στιγμή που ο κινητός πελάτης “κάνει αίτηση” για κάποια δεδομένα μέχρι τη στιγμή που τα δεδομένα αυτά έρχονται στην κατοχή του πελάτη
 - **Probe wait:** Ο μέσος χρόνος από τη στιγμή συντονισμού στο κανάλι μέχρι να βρει τον δείκτη (pointer) για τον επόμενο index. Είναι ίσος με το μισό της απόστασης μεταξύ δυο τμημάτων index.
 - **Bcast wait:** Ο μέσος χρόνος από τη στιγμή που βρίσκεται ο πρώτος index μέχρι να “κατεβούν” όλα τα δεδομένα

Παράμετροι ενδιαφέροντος (2/2)




Querying

Tuning time




Latency



Probe wait

Bcast wait



Οργάνωση του καναλιού εκπομπής

- **Packet**: η βασική (μικρότερη) μονάδα μεταφοράς μηνυμάτων στα δίκτυα
- **Bucket**: η μικρότερη λογική μονάδα εκπομπής. Αποτελείται από σταθερό αριθμό packets. Όλα τα buckets έχουν το ίδιο μέγεθος
 - Index buckets
 - Data buckets
- **Index Segment**: σύνολο συνεχόμενων index buckets
- **Data Segment**: σύνολο συνεχόμενων data buckets


Οργάνωση του καναλιού εκπομπής

- Περιεχόμενα bucket
 - **Bucket_id**: το offset του bucket από την αρχή του κύκλου εκπομπής
 - **Bcast_pointer**: το offset μέχρι την αρχή του επόμενου κύκλου εκπομπής
 - **Index_pointer**: το offset μέχρι την αρχή του επόμενου index segment
 - **Bucket_type**: data bucket ή index bucket
- Index bucket: είναι μια ακολουθία της μορφής:
 - (**attribute_value, offset**): offset είναι ένας δείκτης στο bucket που περιέχει εγγραφή που προσδιορίζεται από την attribute_value

Clustering index

- **Clustering index**: ένα ευρετήριο (index) είναι clustered πάνω σε ένα attribute, εάν όλες οι εγγραφές με την ίδια τιμή για το attribute αυτό, εμφανίζονται συνεχόμενες σε ένα “αρχείο”
- Τα δυο άκρα στην βελτιστοποίηση Tuning time και Access time
 - Latency_opt
 - Tune_opt

Latency OPT




Latency είναι η βέλτιστη: Δεν υπάρχει επιβάρυνση για το index

$$\text{Latency} = \text{Data}/2 + C$$

$$\text{Tuning time} = \text{Data}/2 + C$$

Tuning OPT



Tuning time είναι ο βέλτιστος:

$$\begin{aligned} \text{Latency} &= (\text{Data} + \text{Index}) / 2 + (\text{Data} + \text{Index}) / 2 + C \\ &= \text{Data} + \text{Index} + C \end{aligned}$$

$$\text{Tuning time} = k + C$$


k: number of levels in the index tree

(1, m) Indexing

Το ευρετήριο (index) εκπέμπεται m φορές κατά τη διάρκεια μιας εκπομπής του αρχείου.

Πολυεπίπεδο ευρετήριο (index), δηλαδή δένδρο

Ολόκληρος ο index εκπέμπεται πριν από το $1/m$ κομμάτι του αρχείου.



Ανάλυση (1, m) Indexing

- Η κατανομή πιθανότητας του initial probe για τους πελάτες είναι ομοιόμορφη
- Data: το μέσο μέγεθος του αρχείου
- C: η coarseness του index attribute
- Ο index έχει δείκτες μόνο στην πρώτη εμφάνιση εγγραφής με συγκεκριμένη τιμή για το attribute
- Άρα, κατασκευάζουμε ευρετήριο μόνο για (Data/C) data buckets
- n, η χωρητικότητα ενός bucket, δηλ., ο αριθμός των ζευγών (attribute_value, offset) που μπορεί να στεγάσει
- k: ο αριθμός των επιπέδων του ευρετηρίου
- Index: ο αριθμός των buckets του

Ανάλυση (1, m) Indexing

Όταν το δένδρο είναι πλήρως ισοζυγισμένο

$$k = \left\lceil \log_n \left(\frac{Data}{C} \right) \right\rceil \quad Index = \sum_{i=0}^{k-1} n^i$$

Latency: The *probe wait* is $\frac{1}{2} * (Index + \frac{Data}{m})$ and the *bcast wait* is $\frac{1}{2} * ((m * Index) + Data) + C$. Hence, the latency is

$$\frac{1}{2} * \left(Index + \frac{Data}{m} \right) + \frac{1}{2} * ((m * Index) + Data) + C,$$

i.e.,

$$\frac{1}{2} * \left((m + 1) * Index + \left(\frac{1}{m} + 1 \right) * Data \right) + C.$$

Ανάλυση (1, m) Indexing

Tuning time: $1 + k + C$



•Βέλτιστο m για ελαχιστοποίηση Latency:

- Παραγωγή της εξίσωσης της Latency ως προς m
- Εξίσωση με 0
- Επίλυση ως προς m


$$m^* = \sqrt{\frac{Data}{Index}}$$

Distributed Indexing

- Βελτίωση του (1,m) index ελαττώνοντας τη replication του index
 - Δεν χρειάζεται να εκπέμπεις ολόκληρο τον index μεταξύ διαδοχικών data segments, αλλά μόνο το κομμάτι του που δεικτοδοτεί τα data που έπονται.



Παράδειγμα εργασίας (1/2)



Παράδειγμα εργασίας (2/2)

$NRR = \{ b1, b2, b3, b4, b5, b6, b7, b8, b9 \}$

$Rep(b1) = \{ l, a1 \}$

$Rep(b2) = \{ a1 \}$

$Rep(b3) = \{ a1 \}$

$Rep(b4) = \{ l, a2 \}$

$Rep(b5) = \{ a2 \}$

$Rep(b6) = \{ a2 \}$

$Rep(b7) = \{ l, a3 \}$

$Rep(b8) = \{ a3 \}$

$Rep(b9) = \{ a3 \}$

$Ind(b1) = \{ b1, c1, c2, c3 \}$

$Ind(b2) = \{ b2, c4, c5, c6 \}$

$Ind(b3) = \{ b3, c7, c8, c9 \}$

$Ind(b4) = \{ b4, c10, c11, c12 \}$

$Ind(b5) = \{ b5, c13, c14, c15 \}$

$Ind(b6) = \{ b6, c16, c17, c18 \}$

$Ind(b7) = \{ b7, c19, c20, c21 \}$

$Ind(b8) = \{ b8, c22, c23, c24 \}$

$Ind(b9) = \{ b9, c25, c26, c27 \}$

$Data(b1) = \{ 0, \dots, 8 \}$

$Data(b2) = \{ 9, \dots, 17 \}$

$Data(b3) = \{ 18, \dots, 26 \}$

$Data(b4) = \{ 27, \dots, 35 \}$

$Data(b5) = \{ 36, \dots, 44 \}$

$Data(b6) = \{ 45, \dots, 53 \}$

$Data(b7) = \{ 54, \dots, 62 \}$

$Data(b8) = \{ 63, \dots, 71 \}$

$Data(b9) = \{ 72, \dots, 80 \}$


Εναλλ. μέθοδοι index distribution

- **Nonreplicated Distribution:** διαφορετικά κομμάτια index segments είναι διακριτά, δηλ., δεν υπάρχει replication.
- **Entire Path Replication:** Το μονοπάτι από τη ρίζα μέχρι ένα index bucket B γίνεται replication ακριβώς πριν την εμφάνιση του B.
- **Partial Path Replication:** Έστωσαν δυο index buckets B και B'. Είναι αρκετό να κάνουμε replication το μονοπάτι από τον ελάχιστο κοινό πρόγονο (Least Common Ancestor) των B και B', πριν την εμφάνιση του B', δεδομένου ότι προσθέτουμε κάποια επιπρόσθετη indexing πληροφορία για “προσανατολισμό”.


Nonreplicated Distribution



Entire Path Replication




Distributed Indexing



Exponential Index (1/2)

- Data buckets
 - Data part
 - Index table
 - Index entries:
 - κάθε entry indexes ένα segment από buckets και έχει τη μορφή **{distInt, maxKey}**
 - » distInt: καθορίζει την απόσταση των buckets από το τρέχον bucket (μετρημένο σε αριθμό buckets)
 - » maxKey: είναι η τιμή του μέγιστου κλειδιού αυτών των buckets
 - Τα μεγέθη των segments αυξάνουν εκθετικά (δυνάμεις του 2). Η i -οστή entry περιγράφει το segment των buckets τα οποία είναι σε απόσταση 2^{i-1} έως 2^i-1
 - Προφανώς οι τιμές distInt δεν χρειάζονται αφού μπορούν εύκολα να συναχθούν

Exponential Index (2/2)



Κυρτά πρότυπα προσπέλασης

- Τι γίνεται όταν το πρότυπο προσπέλασης στις εγγραφές δεν είναι ομοιόμορφο?
- Τα ευρετήρια που παρουσιάσαμε είναι κατάλληλα για ομοιόμορφα πρότυπα προσπέλασης
- n : αριθμός εγγραφών
- R_i : i -οστή εγγραφή
- $\Pr(R_i)$: πιθανότητα προσπέλασης εγγραφής R_i
- $I_{pb}(R_i)$: αριθμός index nodes μέχρι να φτάσουμε στην εγγραφή ή index node R_i
- a_i : αναπαριστά έναν index node
- $d(a_i)$: fanout του κόμβου a_i
- $\text{Path}(R_i)$: σύνολο των index nodes από τη ρίζα μέχρι την εγγραφή R_i
- $f(a_i)$: κόστος “ενεργοποίησης” index node a_i . Συνήθως $f(a_i)=d(a_i)$.


Ισοζυγισμένα δενδρικά ευρετήρια

Έστω ότι το μέσο κόστος εντοπισμού μιας εγγραφής εκφράζεται ως:

$$\sum_{1 \leq i \leq n} Pr(R_i) \sum_{a_j \in Path(R_i)} f(a_j)$$

Το διπλανό ευρετήριο είναι βέλτιστο για ομοιόμορφη πιθανότητα προσπέλασης.

Μέσο κόστος: $C(T_{d=3}^B) = 6$




Μη ισοζυγισμένα δενδρικά ευρετήρια σταθερού fanout [π.χ., d=3]

Data record	R1	R2	R3	R4	R5	R6	R7	R8	R9
$Pr(R_i)$	0.4	0.4	0.05	0.05	0.02	0.02	0.02	0.02	0.02
$I_{pb}(R_i)$ in $T_{d=3}^B$	2	2	2	2	2	2	2	2	2
$I_{pb}(R_i)$ in $T_{d=3}^I$	1	1	2	3	3	3	3	3	3

$$\begin{aligned}
 C(T_{d=3}^I) &= 0.4*3 + 0.4*3 + && \text{[για } R_1 \text{ και } R_2\text{]} \\
 &0.05*(3+3) + && \text{[για } R_3\text{]} \\
 &0.05*(3+3+3) + && \text{[για } R_4\text{]} \\
 &5*0.02*(3+3+3) && \text{[για υπόλοιπες]} \\
 &= 0.4*6 + 0.05*15 + 45*0.02 = \mathbf{4.28}
 \end{aligned}$$

Σειρά εκπομπής στο ασύρματο κανάλι

I	R1	R2	a1	R3	a2	R4	R5	R6	a3	R7	R8	R9
---	----	----	----	----	----	----	----	----	----	----	----	----



Αλγόριθμος κατασκευής $T^I_{d=j}$

Algorithm CF: Use access frequencies to build an index tree with a fixed fanout d .


Step 1: Initially, we have a forest of n subtrees, each of which is a single node labeled with the corresponding access frequency.

Step 2: Attach the d subtrees with the smallest labels to a new node. Label the resulting subtree with the sum of all labels from its d child subtrees.


Step 3: $n = n - d + 1$. (Then, n is the number of remaining subtrees.) If $n = 1$ stop else goto Step 2.

**Κατασκευάζει ένα Huffman δένδρο με fanout = d .
Στο βασικό Huffman δένδρο, fanout = 2.**

Μη ισοζυγισμένα δενδρικά ευρετήρια σταθερού fanout [π.χ., $d=2$]



Μη ισοζυγισμένα δενδρικά ευρετήρια σταθερού fanout [π.χ., $d=4$]



Μη ισοζυγισμένα δένδρα σταθερού fanout


- Δεν υπάρχει μονοτονική σχέση, ούτε αύξουσα ούτε φθίνουσα, για τις τιμές κόστους $C(T^I_{d=j})$ σε σχέση με το επιτρεπτό fanout j .
- Αυτό το γεγονός, σε συνδυασμό με την ιεραρχική φύση της κατασκευής, υπονοεί ότι, επιτρέποντας μεταβλητά fanouts στους κόμβους του δένδρου, μπορούμε να ελαττώσουμε ακόμα περισσότερο το μέσο κόστος εντοπισμού των εγγραφών

Βασική ιδέα (1/2)

Lemma 1. *Suppose that node r has m child nodes, $h_1, h_2, \dots$, and h_m , which are sorted according to descending order of $Pr(h_j)$, $1 \leq j \leq m$, i.e., $Pr(h_j) \geq Pr(h_k)$ if and only if $j \leq k$. Then, the average cost of index probes can be reduced by grouping nodes $h_{i+1}, h_{i+2}, \dots$, and h_m and attaching them under a new child node if and only if*

$$(m - i - 1) \sum_{1 \leq j \leq i} Pr(h_j) > \sum_{i+1 \leq j \leq m} Pr(h_j).$$

Βασική ιδέα (2/2)



Μη ισοζυγισμένα δένδρα μεταβλητού fanout T^I_V : Αλγόριθμος κατασκευής

Algorithm VF:

Step 1: Assume that $R_1, R_2, \dots$, and R_n have been sorted according to descending order of $Pr(R_j)$, $1 \leq j \leq n$, i.e.,
 $Pr(R_j) \geq Pr(R_k)$ iff. $j \leq k$.

Step 2: *Partition* ($R_1, R_2, \dots, R_n$).


Step 3: Report the resulting index tree.

Μη ισοζυγισμένα δένδρα μεταβλητού fanout T^I_V : Αλγόριθμος κατασκευής

Procedure *Partition* ($h_1, h_2, \dots, h_m$):


1. Let $y(i) = (m - i - 1) \sum_{1 \leq j \leq i} Pr(h_j) - \sum_{i+1 \leq j \leq m} Pr(h_j)$.
Determine i^* such that $y(i^*) = \max_{\forall i \in \{1, m-2\}} \{y(i)\}$.
2. If $y(i^*) \leq 0$, then return.
3. Attach nodes $h_{i^*+1}, h_{i^*+2}, \dots, h_m$ under a new index node hx in the index tree.
4. *Partition* ($h_{i^*+1}, h_{i^*+2}, \dots, h_m$).
5. Insert hx into the ordered list $(h_1, h_2, \dots, h_{i^*})$ and relabel them as $(h_1, h_2, \dots, h_{i^*+1})$ according to descending order of $Pr(h_j)$, $1 \leq j \leq i^* + 1$.
6. *Partition* ($h_1, h_2, \dots, h_{i^*+1}$).
7. Return.

Παράδειγμα κατασκευής T_V^I (1/6)




i	1	2	3	4	5	6	7	8	9
$(10 - i) \sum_{1 < j < i} Pr(h_j)$	9*.208	8*0.48	7*0.68	6*0.88	5*0.92	4*0.96	3*0.98	2*0.985	0.99
$\sum_{i+1 < j < 11} Pr(h_j)$	0.72	0.52	0.32	0.12	0.08	0.04	0.02	0.015	0.01
$y(i)$	1.8	3.32	4.44	5.16	4.52	3.8	2.92	1.955	0.98

Παράδειγμα κατασκευής T_V^I (2/6)




Παράδειγμα κατασκευής T_V^I (3/6)


i	1	2	3
$(4 - i) \sum_{1 < j < i} Pr(h_j)$	$3 * 0.28$	$2 * 0.48$	0.68
$\sum_{i+1 \leq j \leq 5} Pr(h_j)$	0.72	0.52	0.32
$y(i)$	0.12	0.44	0.32




Παράδειγμα κατασκευής T_V^I (4/6)



Παράδειγμα κατασκευής T_V^I (5/6)




Παράδειγμα κατασκευής T_V^I (6/6)




$$C(T_V^I) = 5.08$$

Αντιδιαστολή T^I_V με $T^I_{d=2}$ και $T^I_{d=3}$



$$C(T^I_{d=2}) = 5.20$$




$$C(T^I_{d=3}) = 5.625$$


“Αλφαβητικά” δενδρικά ευρετήρια

- Ομοιόμορφη προσπέλαση & ταξινομημένα κλειδιά
 - (1,m) indexing
 - Distributed indexing
 - Exponential indexing
- Μη ομοιόμορφη προσπέλαση & μη ταξινομημένα κλειδιά
 - $T^I_{d=j}$
 - T^I_V
- Μη ομοιόμορφη προσπέλαση & ταξινομημένα κλειδιά ????

Το πρόβλημα των Huffman δένδρων




Τα Alphabetic δένδρα




Παράδειγμα κατασκευής δυαδικού αλφαβητικού δένδρου

A	B	C	D	E	F	G	H	I	J	K
8	6	2	3	4	7	11	9	8	1	3


Παράδειγμα Alphabetic tree (1/4)



Παράδειγμα Alphabetic tree (2/4)



Παράδειγμα Alphabetic tree (3/4)



Alphabetic tree (4/4)

