



Προγραμματισμός II (ECE116)

#7

πίνακες κατακερματισμού (hash tables)

Δομές αναζήτησης ... μέχρι στιγμής

Δομή	Πολυπλοκότητα αναζήτησης
Table	$O(N)$
Sorted Table	$O(\log_2 N)$
List	$O(N)$
Sorted List	$O(N)$
Balanced Tree*	$O(\log_2 N)$

*θα γίνει αργότερα, αν προλάβουμε

Υπάρχει κάτι καλύτερο;

- Ένα ιδανικό ευρετήριο θα υποστήριζε την λειτουργία αναζήτησης (ιδανικά και προσθήκης / απομάκρυνσης) με **σταθερό** κόστος
- **Ανεξάρτητα** από το πλήθος των στοιχείων που περιέχει το ευρετήριο
- Μια τέτοια ιδιότητα φαίνεται αδύνατη
- Με κατάλληλα «μαγικά», είναι εφικτή
- **Πίνακες κατακερματισμού** (hash tables)

Δομές αναζήτησης

Δομή	Πολυπλοκότητα αναζήτησης
Table	$O(N)$
Sorted Table	$O(\log_2 N)$
List	$O(N)$
Sorted List	$O(N)$
Balanced Tree	$O(\log_2 N)$
Hashtable	$O(1)$

Πίνακας κατακερματισμού


- Ειδικός δυναμικός πίνακας από **δοχεία** (buckets) που περιέχουν τις εγγραφές (δομές με δεδομένα)
 - πίνακας N θέσεων: N δοχεία
- Η αντιστοίχιση των εγγραφών στα δοχεία του πίνακα γίνεται χρησιμοποιώντας ως «κλειδί» την τιμή από ένα ή περισσότερα πεδία της εγγραφής
- Το κλειδί **μετασχηματίζεται** μέσα από μια **συνάρτηση κατακερματισμού** (hash function)
- Η συνάρτηση επιστρέφει την τιμή (hash value) που **υποδεικνύει την θέση** (το δοχείο) όπου βρίσκεται (ή πρέπει να εισαχθεί) η εγγραφή
 - η τιμή περιορίζεται στο μέγεθος του πίνακα (με modulo)



hash_function(key) -> index




π.χ., integers, strings





hash_function:


`str[0] % 4`







0	
1	
2	
3	

























Συγκρούσεις – Δοχεία


- Η συνάρτηση κατακερματισμού μπορεί να επιστρέψει την **ίδια τιμή** για **διαφορετικές** τιμές κλειδιών
- Αυτό ονομάζεται **σύγκρουση** (collision)
- Οι εγγραφές με ίδια hash values αντιστοιχίζονται στο **ίδιο** δοχείο
- Πρέπει να υποστηριχθεί προσθήκη, αναζήτηση και απομάκρυνση εγγραφών μέσα **στα δοχεία**
 - με βάση την τιμή του κλειδιού (αφού το hash value είναι το ίδιο)
- Τα δοχεία υλοποιούνται με **δομές αναζήτησης**
- Δυναμικός πίνακας, λίστα, δέντρο ή άλλο ένα hash table!






bucket




















add(Babis)

hash_function:
 $\text{str}[0] \% 4$







0		Lena	
1		Anna	Manos
2		Vana	Babis
3		Giorgos	Katia



hash_function:

`str[0] % 4`



Απόδοση / κόστος αναζήτησης

Καλή απόδοση

- Ο πίνακας έχει **αρκετά μεγάλο** μέγεθος
- Χρησιμοποιείται **καλή** συνάρτηση κατακερματισμού
 - υπάρχει **ομοιόμορφη** κατανομή των εγγραφών στα δοχεία
- Κάθε δοχείο έχει πολύ **λίγες** εγγραφές

=> κόστος αναζήτησης: $O(1)$


Κακή απόδοση

- Ο πίνακας έχει **μικρό** μέγεθος
 - νομοτελειακά όλα τα δοχεία θα έχουν πολλές εγγραφές
- Χρησιμοποιείται **κακή** συνάρτηση κατακερματισμού
 - κάποια δοχεία έχουν πολλές εγγραφές ενώ άλλα πολύ λίγες

=> κόστος αναζήτησης: αναζήτηση μέσα στα δοχεία


καλή κατανομή

σχετικά μικρό
μέγεθος πίνακα




κακή κατανομή

σχετικά **επαρκές**
μέγεθος πίνακα




καλή κατανομή

σχετικά **μεγάλο**
μέγεθος πίνακα



καλή κατανομή

καλό μέγεθος
πίνακα



Μετρικές

- Μέγεθος του πίνακα (N)
- Αριθμός εισαγωγών (E)
- Μέγεθος δοχείων (B)
- **Load factor (LF):** E/N
 - $\ll 1 \Rightarrow$ ο πίνακας είναι υπο-φορτωμένος
 - $> 1 \Rightarrow$ ο πίνακας είναι υπερ-φορτωμένος
- **Max/mean/average B**
 - $\gg 1 \Rightarrow$ σχετικά αργή αναζήτηση μέσα στα δοχεία
 - αναλόγως με την δομή που χρησιμοποιείται εσωτερικά
 - $\sim 1 \Rightarrow$ γρήγορη αναζήτηση μέσα στα δοχεία

Τακτικές βελτίωσης απόδοσης

- Δυναμική αύξηση του μεγέθους του πίνακα
 - όταν $LF > 1$
 - για να επιτευχθεί μείωση του μεγέθους δοχείων
- Δυναμική μείωση του μεγέθους του πίνακα
 - όταν $LF \ll 1$
 - για να αποφευχθεί σπατάλη μνήμης
- Αλλαγή της συνάρτησης κατακερματισμού
 - όταν $\min/\max B \gg 1$ και $LF < 1$
 - για να επιτευχθεί καλύτερη κατανομή ανάμεσα στα δοχεία

Ανακατακερματισμός (rehashing)



- Όταν αλλάξει το μέγεθος του πίνακα ή/και η συνάρτηση κατακερματισμού, πρέπει να γίνει **αναδιάταξη** των εγγραφών
- Αυτό ονομάζεται **ανακατακερματισμός** (rehashing)



Απλή υλοποίηση


- Δημιουργία νέου πίνακα κατακερματισμού με άδεια δοχεία
- Αφαίρεση κάθε μιας εγγραφής από τον παλιό πίνακα και εισαγωγή της στον νέο πίνακα
 - μέχρι να αδειάσουν όλα τα δοχεία του παλιού πίνακα
- Καταστροφή του παλιού πίνακα

hash_function:


`str[0] % 4`









0		Lena
1		Anna Manos
2		Babis Vana
3		Giorgos Katia

Olga 

hash_function:
 $\text{str}[0] \% 4$



add(Olga)



rehash entries


new
hash_function:
`str[0] % 8`

add(**O**lga)



add(**O**lga)


hash_function:
`str[0] % 8`




add(**Olga**)

hash_function:

`str[0] % 8`






$$79 \% 8 = 7$$



add(Pavlos)

hash_function:
 $\text{str}[0] \% 8$





add(Nikos)

hash_function:

$\text{str}[0] \% 8$




0	→	Pavlos
1	→	Anna
2	→	Babis
3	→	Katia
4	→	Lena
5	→	Manos
6	→	Vana
7	→	Giorgos Olga

add(Nikos)

hash_function:

$\text{str}[0] \% 8$




$$78 \% 8 = 6$$

0	→	Pavlos	
1	→	Anna	
2	→	Babis	
3	→	Katia	
4	→	Lena	
5	→	Manos	
6	→	Vana	Nikos
7	→	Giorgos	Olga


add(Nikos)

hash_function:

$\text{str}[0] \% 8$



hash_function:
`str[0] % 8`



rmv (Olga)


hash_function:



$\text{str}[0] \% 8$




0	→	Pavlos	
1	→	Anna	
2	→	Babis	
3	→	Katia	
4	→	Lena	
5	→	Manos	
6	→	Nikos	Vana
7	→	Giorgos	Olga

hash_function:
`str[0] % 8`






hash_function:
`str[0] % 8`




rmv (Katia)



hash_function:

$\text{str}[0] \% 8$






hash_function:
`str[0] % 8`






hash_function:
`str[0] % 8`






hash_function:
`str[0] % 8`




rmv (Nikos)


hash_function:


$\text{str}[0] \% 8$




hash_function:
`str[0] % 8`










hash_function:
`str[0] % 4`



hash_function:
`str[0] % 4`

