



Προγραμματιστικές Τεχνικές

Δυναμικές δομές χειρισμού συνόλων: δομές ένωσης-
εύρεσης – ουρές προτεραιότητας – κατακερματισμός

Union-Find, Heaps, Hashing

Διδάσκοντες

Βασίλης Βεσκούκης

Νίκος Λεονάρδος

Άρης Παγουρτζής

Νίκος Παπασπύρου

Πέτρος Ποτίκας

Σωτήρης Κοκόσης

Γιώργος Σιόλας

progtech@cslab.ece.ntua.gr

Επιμέλεια διαφανειών: Άρης Παγουρτζής (ΕΜΠ)

Δομές UNION-FIND


Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Εφαρμογές: **ανίχνευση κοινοτήτων** (community detection), (δυναμική) συνεκτικότητα - **συνεκτικές συνιστώσες** (connected components), αλγόριθμος **Kruskal** για **ελάχιστο συνδετικό δέντρο** (minimum spanning tree), και πολλές άλλες

Δομές UNION-FIND

Ε


- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Υλοποίηση συνόλων με δέντρα: ένα δέντρο για κάθε σύνολο, «αντιπρόσωπος» η ρίζα



Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Απλή υλοποίηση: με pointers ή array



Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Απλή υλοποίηση: με pointers ή array
- Δημιουργία: $O(1)$
- Ένωση: ?




{8}

Makeset(8)

Δομές UNION-FIND

- Ε • Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Απλή υλοποίηση: με pointers ή array
- Δημιουργία: $O(1)$
- Ένωση: $O(1)$
- Εύρεση: ?




Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Απλή υλοποίηση: με pointers ή array
- Δημιουργία: $O(1)$
- Ένωση: $O(1)$
- Εύρεση: $O(n)$

χειρότερη περίπτωση!
Γίνεται καλύτερα;



Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Υλοποίηση συνόλων με δένδρα: ένα δένδρο για κάθε σύνολο, «αντιπρόσωπος» η ρίζα, κόμβοι δείχνουν προς τον γονέα
- Απλή υλοποίηση: με pointers ή array
- Δημιουργία: **$O(1)$**
- Ένωση: **$O(1)$**
- Εύρεση: **$O(\log n)$** με **Union-by-Size**

Δομές UNION-FIND

Ε

- Εύρεση: $O(\log n)$ με **Union-by-Size** :
το δέντρο με τα λιγότερα στοιχεία «κρεμιέται» στη ρίζα του δέντρου με τα περισσότερα στοιχεία
 - παραλλαγές: **Union-by-Height**, **Union-by-Rank**

Ισχυρισμός: κάθε δένδρο n κόμβων που προκύπτει με διαδοχικές εφαρμογές Union-by-Size έχει ύψος

$$h \leq \log_2 n$$

Απόδειξη: με επαγωγή στην κατασκευή του δένδρου

Δομές UNION-FIND

Ε

Θεώρημα: κάθε δένδρο n κόμβων που προκύπτει με διαδοχικές εφαρμογές Union-by-Size έχει ύψος

$$h \leq \log_2 n$$

Απόδειξη: με επαγωγή στην κατασκευή του δένδρου :

Θεωρήστε δένδρο ύψους h με n κόμβους, από ένωση δύο δένδρων με ύψη $h_1 \leq \log_2 n_1$, $h_2 \leq \log_2 n_2$

Έστω χ.β.γ. ότι $n_1 \leq n_2$

Αν $h_1 < h_2$ τότε $h = h_2 \leq \log_2 n_2 < \log_2 n$

Αν $h_1 \geq h_2$ τότε $h = h_1 + 1 \leq \log_2 (2n_1) \leq \log_2 n$



Δομές UNION-FIND

- Ε • Πολυπλοκότητα πράξεων συνόλων:
 - Δημιουργία: $O(1)$
 - Ένωση: $O(1)$
 - Εύρεση: $O(\log^* n)$ *αποσβετικά* (amortized analysis) σε σύνολο m πράξεων

με **Union-by-Rank + Path Compression** (σε κάθε εύρεση όλα τα στοιχεία του μονοπατιού προς την ρίζα τα «κρεμάμε» κατευθείαν στη ρίζα)

($\log^* n \leq 5$ για $n \leq 2^{65536}$!!)

Δομές UNION-FIND

- Ε • Πολυπλοκότητα πράξεων συνόλων :
 - Δημιουργία: $O(1)$
 - Ένωση: $O(1)$
 - Εύρεση: $O(\alpha(n))$ *αποσβετικά* (amortized analysis)
σε σύνολο m πράξεων
(με πιο πολύπλοκη ανάλυση)



με **Union-by-Rank + Path Compression**

$\alpha(n) \leq 4$ για $n \leq 2^{2^{2^{65536}}} - 3$, αντίστροφη Ackermann

Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Υλοποίηση με **πίνακα**




1	2	3	4	5	6	7	8
1	5	1	6	1	6	6	8

Δομές UNION-FIND

Ε

- Υποστηρίζουν πράξεις συνόλων:
 - Δημιουργία συνόλου [**Makeset**]
 - Εύρεση (αναζήτηση) [**Find**]
 - Ένωση [**Union**]
- Υλοποίηση με **πίνακα**



Ουρά προτεραιότητας (priority queue)



- Δομή για αποθήκευση συνόλου στοιχείων με **σχέση προτεραιότητας** ανάμεσα στα στοιχεία του (ολική διάταξη)
 - π.χ. προηγούνται τα μεγαλύτερα στοιχεία
- Εφαρμογές:
 - εξυπηρέτηση κατά προτεραιότητα
 - διαχείριση bandwidth
 - ταξινόμηση
 - αλγόριθμος Dijkstra (shortest paths) και αλγόριθμος Prim (minimum spanning tree)
 - κωδικοποίηση Huffman

Ουρά προτεραιότητας (priority queue)



- Δομή για αποθήκευση συνόλου στοιχείων με **σχέση προτεραιότητας** ανάμεσα στα στοιχεία του (ολική διάταξη)
 - π.χ. προηγούνται τα μεγαλύτερα στοιχεία
- Απαραίτητες λειτουργίες:
 - **δημιουργία** ουράς
 - **εισαγωγή** στοιχείου
 - **διαγραφή** στοιχείου
 - **ανάκτηση** (και διαγραφή) στοιχείου **μέγιστης προτεραιότητας**

Ουρές προτεραιότητας: απλοϊκή υλοποίηση

- Με γραμμική δομή (list):
 - εισαγωγή σε χρόνο $O(1)$
 - ανάκτηση (και διαγραφή) στοιχείου μέγιστης προτεραιότητας: χρόνος $O(n)$

Ουρές προτεραιότητας: απλοϊκή υλοποίηση




- Με γραμμική δομή (list):
 - εισαγωγή σε χρόνο $O(1)$
 - **ανάκτηση (και διαγραφή)** στοιχείου μέγιστης προτεραιότητας: χρόνος $O(n)$
- Εναλλακτικά (list):
 - εισαγωγή σε χρόνο $O(n)$ (για ταξινόμηση)
 - **ανάκτηση (και διαγραφή)** στοιχείου μέγιστης προτεραιότητας: χρόνος $O(1)$
- Παρόμοιοι χρόνοι με χρήση array

Σωρός (heap)



- Ένας καλύτερος τρόπος υλοποίησης ουράς προτεραιότητας
- **Δυαδικός σωρός** (binary heap):
 - πλήρες δυαδικό δένδρο
 - ελάχιστο (ή μέγιστο) στοιχείο στην ρίζα
 - κάθε υποδένδρο είναι επίσης δυαδικός σωρός
 - απλή υλοποίηση με **πίνακα**




Δυαδικός σωρός
ελαχίστου

Υλοποίηση σωρού με πίνακα

- Παιδιά του $A[i]$: $A[2i]$, $A[2i+1]$
- Γονέας του $A[i]$: $A[i/2]$
- Τα στοιχεία του σωρού γράφονται σε συνεχόμενες θέσεις του πίνακα σε σειρά αντίστοιχη της εξερεύνησης BFS

Δυαδικός σωρός
ελαχίστου




A[1]	A[2]	A[3]	A[4]	A[5]	A[6]	A[7]	A[8]	A[9]	A[10]
3	6	4	8	11	10	15	16	9	12

Σημαντικές ιδιότητες δυαδικών σωρών




- ύψος δένδρου: $O(\log_2 n)$
#κόμβων σε δένδρο ύψους h : $2^h \leq n < 2^{h+1}$
- άμεση ανάκτηση στοιχείου μέγιστης προτεραιότητας: $O(1)$
- εισαγωγή και διαγραφή σε χρόνο $O(\log_2 n)$
- τώρα θα δούμε πώς



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5



**Δυαδικός σωρός
ελαχίστου**

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[n+1]$)



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[n+1]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[11]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[11]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[11]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[11]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[n+1]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό


- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[n+1]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...
- Χρόνος εισαγωγής: $O(\log n)$ – γιατί;



Δυαδικός σωρός
ελαχίστου

Εισαγωγή σε δυαδικό σωρό

- Έστω ότι θέλουμε να εισαγάγουμε ένα νέο στοιχείο με τιμή 5
- Αρχικά τοποθετούμε το στοιχείο μετά την τελευταία θέση ($A[n+1]$)
- Συγκρίνουμε με τον γονέα και αν χρειάζεται ανταλλάσσουμε τα στοιχεία:
 $\text{swap}(A[i], A[i/2])$
- Επαναλαμβάνουμε ...
- Χρόνος εισαγωγής: $O(\log n) \sim$ ύψος δένδρου




Δυαδικός σωρός
ελαχίστου

Μικρή βελτίωση: δεν χρειάζεται να κάνουμε swap , απλά $A[i] \leftarrow A[i/2]$ ώσπου να “αδειάσει” η σωστή θέση

Διαγραφή από δυαδικό σωρό

- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)




Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό



- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»




**Δυαδικός σωρός
ελαχίστου**

Διαγραφή από δυαδικό σωρό




- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται
- Επαναλαμβάνουμε ...



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό


- Έστω ότι θέλουμε να διαγράψουμε το ελάχιστο στοιχείο (ρίζα)
- Η τελευταία θέση «περισσεύει»
- Τοποθετούμε το στοιχείο της τελευταίας θέσης ($A[n]$) στη ρίζα
- «Κυλάμε» το στοιχείο προς τα κάτω συγκρίνοντας με το μικρότερο παιδί και ανταλλάσσοντας (swap) αν χρειάζεται
- Επαναλαμβάνουμε ...
- Χρόνος ανακατασκευής: $O(\log n)$ – γιατί;



Δυαδικός σωρός
ελαχίστου

Διαγραφή από δυαδικό σωρό => μέθοδος (ανα)κατασκευής

- Η διαδικασία διαγραφής ουσιαστικά υποδεικνύει διαδικασία **ανακατασκευής** του σωρού όταν τα υποδένδρα είναι σωροί αλλά η ρίζα είναι μεγαλύτερη από το ένα ή και τα δύο παιδιά της
- Αυτή η διαδικασία λέγεται **Heapify** ή **Combine** στη βιβλιογραφία και είναι χρήσιμη γενικότερα
- Για παράδειγμα, μπορούμε με χρήση της διαδικασίας αυτής να κατασκευάσουμε σωρό με n στοιχεία σε **συνολικό χρόνο $O(n)$** (αντί για **$O(n \log n)$** με χρήση διαδοχικών εισαγωγών) – πώς;
- Ερώτημα: πώς κάνουμε **ενημέρωση** τιμής;



Δυαδικός σωρός
ελαχίστου

Ταξινόμηση με σωρό (HeapSort)

- Έστω ότι θέλουμε να ταξινομήσουμε n αριθμούς (ή στοιχεία)
- Τα εισάγουμε σε σωρό με n διαδοχικές εισαγωγές: $O(n \log n)$ [ή χρησιμοποιούμε Heapify, $O(n)$]
- Επαναλαμβάνουμε n φορές:
 - διαγραφή ελαχίστου (και ανακατασκευή σωρού) και εισαγωγή του σε λίστα
- Συνολικός χρόνος διαγραφών: $O(n \log n)$
- Πολυπλοκότητα HeapSort: $O(n \log n)$
- Εναλλακτικά: **σωρός μεγίστου**, διαγράφουμε διαδοχικά μέγιστο και το εισάγουμε στην τελευταία θέση (ταξινόμηση *επί τόπου* !)

Κατακερματισμός (Hashing)

- 
- Έστω ότι θέλουμε να καταγράψουμε την εμφάνιση δεδομένων (ή κλειδιών / κωδικών) σε ευρετήριο (λεξικό)
 - ...ώστε να μπορούμε να ελέγξουμε αν κάποιο κλειδί έχει εμφανιστεί στα δεδομένα μας (και πόσες φορές)
 - Τα δεδομένα μας έρχονται από ένα σύνολο N δυνατών κλειδιών, όπου το N μπορεί να είναι πολύ μεγάλο
 - Εκτιμούμε ότι θα λάβουμε $m \ll N$ κλειδιά
 - Πόσο καλά μπορούμε να το κάνουμε;

Κατακερματισμός (Hashing)

Εφαρμογές

- Καταμέτρηση διαφορετικών ή επαναλαμβανόμενων δεδομένων / γεγονότων από ένα stream (την τελευταία μέρα, εβδομάδα, κ.λπ. ή σε ένα «παράθυρο» k στοιχείων, π.χ. $k=10^6$): παραγγελίες προϊόντων, αλληλεπιδράσεις σε κοινωνικά δίκτυα, αστρονομικές παρατηρήσεις, τιμές μετοχών, κ.λπ.
- Δίκτυα: δρομολόγηση, εξισορρόπηση φορτίου
- Κρυπτογραφία: passwords, ψηφιακές υπογραφές, proof-of-work (blockchains), ακεραιότητα δεδομένων
- Πάρα πολλές διαφορετικές χρήσεις
- Κοινός τόπος: αποφυγή συγκρούσεων (στην κρυπτογραφία εντελώς)


Κατακερματισμός (Hashing)



- Δεδομένα από σύνολο N δυνατών κλειδιών, όπου το N μπορεί να είναι πολύ μεγάλο
- Εκτιμούμε ότι θα λάβουμε $m \ll N$ κλειδιά
- Πόσο καλά μπορούμε να το κάνουμε;
- Θέλουμε γρήγορη καταχώρηση και ανάκτηση, ιδανικά $O(1)$
- Εφικτό με χρήση array – αλλά «σπάταλο» σε μνήμη (ιδέες από **bucket sort**)
- Εφικτό με λίγη μνήμη, με χρήση **συναρτήσεων κατακερματισμού** (hash functions)

Κατακερματισμός (Hashing)


- Απεικόνιση ενός μεγάλου συνόλου σε ένα πολύ μικρότερο
- Όσο το δυνατόν πιο ομοιόμορφα
- Στόχος: **ελαχιστοποίηση συγκρούσεων**
- (Διαφορά με κρυπτογραφικό hashing: εκεί **απαγορεύονται** οι συγκρούσεις)



Κατακερματισμός (Hashing)

■ Μέθοδος διαίρεσης

- Απλή μορφή: $h(k) = k \bmod m$




Κατακερματισμός (Hashing)

■ Μέθοδος διαίρεσης

- Απλή μορφή: $h(k) = k \bmod m$
- Μειονέκτημα: δεν έχει ιδιότητα **καθολικότητας**

Καθολική (universal)
συνάρτηση κατακερ/σμού:

απεικονίζει διαφορετικά
κλειδιά στην ίδια θέση με
πιθανότητα $\leq 1/m$



Κατακερματισμός (Hashing)


■ Μέθοδος διαίρεσης

- Απλή μορφή: $h(k) = k \bmod m$
- Μειονέκτημα: δεν έχει ιδιότητα **καθολικότητας**

Καθολική (universal)
συνάρτηση κατακερ/σμού:

απεικονίζει διαφορετικά
κλειδιά στην ίδια θέση με
πιθανότητα $\leq 1/m$

- **Αδύνατο** για μία μόνο
συνάρτηση! (γιατί;)



Κατακερματισμός (Hashing)


■ Μέθοδος διαίρεσης

- Απλή μορφή: $h(k) = k \bmod m$
- Μειονέκτημα: δεν έχει ιδιότητα **καθολικότητας**

Καθολική (universal)
συνάρτηση κατακερ/σμού:

απεικονίζει διαφορετικά
κλειδιά στην ίδια θέση με
πιθανότητα $\leq 1/m$


- **Αδύνατο** για μία μόνο
συνάρτηση:
ντετερμινισμός!



Κατακερματισμός (Hashing)

■ Μέθοδος διαίρεσης


- Οικογένεια συναρτήσεων:
 $h_{a,b}(k) = ak + b \bmod m$
- Έχει ιδιότητα **καθολικότητας**;



Κατακερματισμός (Hashing)

■ Μέθοδος διαίρεσης

- Οικογένεια συναρτήσεων:
 $h_{a,b}(k) = ak + b \bmod m$
- Έχει ιδιότητα *καθολικότητας*;
- Όχι! (γιατί;)



Κατακερματισμός (Hashing)

■ Μέθοδος διαίρεσης


- Καθολική οικογένεια συναρτήσεων:

$$h_{a,b}(k) = (ak + b \bmod p) \bmod m$$

- $p > |U| \gg m$, p πρώτος αριθμός

- Έχει ιδιότητα **καθολικότητας!**

- Απόδειξη: άσκηση (προαιρετική)



Κατακερματισμός (Hashing)

Μέθοδος πολλαπλασιασμού

- Απλή μορφή: $h(k) = (ak \bmod 2^w) \div 2^{w-r}$ $[m = 2^r]$


- Οικογένεια συναρτήσεων:

$$h(k) = (ak + b \bmod 2^w) \div 2^{w-r}$$

- Πλεονεκτήματα:

- εύκολη υλοποίηση
- ιδιότητα **2-καθολικότητας**


ομ/φα τυχαία επιλογή a, b ,
απεικονίζει διαφορετικά
κλειδιά στην ίδια θέση με
πιθανότητα $\leq 2/m$



Κατακερματισμός (Hashing)

• Άμεση / κλειστή διευθυνσιοδότηση (direct / closed addressing)

- Κάθε κλειδί απεικονίζεται στην ίδια πάντα θέση
- Συγκρούσεις αντιμετωπίζονται με αλυσίδωση
- Μέθοδος διαίρεσης, μέθοδος πολλαπλασιασμού
- Σημαντικό μέγεθος: παράγοντας φόρτου
$$a = n / m > 1$$
- Πολυπλοκότητα εισαγωγής, αναζήτησης, διαγραφής:
 $O(1+a)$ [αναμεν/νος # βημάτων]



Κατακερματισμός (Hashing)

• **Ανοιχτή διευθυνσιοδότηση (open addressing)**


- Αποφυγή συγκρούσεων με κατάλληλη αλλαγή θέσης
- Γραμμική και τετραγωνική διερεύνηση, διπλός κατακερματισμός, μέθοδος «κούκου»

- Σημαντικό μέγεθος: **παράγοντας φόρτου**

$$a = n / m < 1$$

- Πολυπλοκότητα εισαγωγής, αναζήτησης, διαγραφής:
 $O(1/(1-a))$ [αναμ/νος # δοκιμών για ομοιόμορφα τυχαία διερεύνηση (διπλός κατακερματισμός την προσεγγίζει καλά)]

$O(1)$ για σταθερό a (π.χ. ≤ 2 για $a \leq 0.5$)



Σύνοψη

Είδαμε 3 μεθόδους διαχείρισης δεδομένων:

Δομές Union-Find για ομαδοποίηση δεδομένων σε σύνολα με υποστήριξη ταχείας *ένωσης συνόλων* και *εύρεσης συνόλου* που ανήκει κάθε στοιχείο

Ουρές προτεραιότητας για διαχείριση δεδομένων με τιμές προτεραιότητας και υποστήριξη ταχείας *ανάκτησης στοιχείου μέγιστης προτεραιότητας*

Συναρτήσεις κατακερματισμού για συνοπτική αποτύπωση δεδομένων με υποστήριξη ταχέος *ελέγχου (επαν)εμφάνισης* στοιχείων