




Ροές



- Ορισμοί
 - Δίκτυο Μεταφοράς ή Ροής
 - Βεβαρημένο γράφημα με χωρητικότητες
 - Πηγή, Καταβόθρα
 - Ροή
 - Απεικόνιση τιμών στις ακμές, φραγμένων από τις αντίστοιχες χωρητικότητες
 - Κορεσμένες, Ακόρεστες ακμές
 - Μέγιστη ροή
 - Τομή
 - Χωρητικότητα Τομής
 - Χωρητικότητα Δικτύου
- Ισοδυναμία Μέγιστης Ροής-Ελάχιστης Τομής



Βοηθητικές Συνδυαστικές Δομές



- Υπολειμματικό Γράφημα

- Για κάθε ροή ακμής, περιέχει δύο ακμές: **προωθήσεως** και **ακυρώσεως ροής**



- Επαυξητικό μονοπάτι

- Κάθε μονοπάτι στο υπολειμματικό γράφημα από την πηγή στην καταβόθρα, με τιμή ροής ίση με την ελάχιστη τιμή ακμής
- Βοηθά στην εύρεση, νέας, βελτιωμένης ροής



Θεώρημα Επαυξητικού Μονοπατιού

- Ροή Μέγιστη αν το αντίστοιχο υπολειμματικό γράφημα δεν διαθέτει επαυξητικό μονοπάτι
 - Έστω μέγιστη ροή. Εάν υπήρχε επαυξητικό μονοπάτι, τότε θα ήταν δυνατή η επαύξηση (άτοπο)
 - Εάν δεν υπάρχει επαυξητικό μονοπάτι, οι κορυφές χωρίζονται σε δύο σύνολα V , V' : το πρώτο περιλαμβάνει τις προσπελάσιμες από την πηγή κορυφές και το δεύτερο τις υπόλοιπες. Τότε,
 - Ακμές V προς V' κορεσμένες
 - Ακμές V' προς V δίχως ροή
 - V , V' τομή, όπου η χωρητικότητα φράσσει την ροή







Θεώρημα Ακέραιας Ροής

- Εάν οι χωρητικότητες είναι ακέραιες τότε και η μέγιστη ροή έχει ακέραια τιμή
 - Παρατηρούμε ότι τα επαυξητικά μονοπάτια έχουν ακέραιες τιμές ροών





Μέθοδος Ford-Fulkerson

- Βασίζεται στο θεώρημα επαυξητικού μονοπατιού:
«όσο υπάρχουν επαυξητικά μονοπάτια, διαλέγουμε ένα και επαυξάνουμε την ροή κατά μήκος του»
- Αποκαλείται μέθοδος, γιατί **δεν** προσδιορίζεται πώς θα βρεθεί το επαυξητικό μονοπάτι
- Στην σχετική δημοσίευση, οι Ford-Fulkerson είχαν προτείνει γενικευμένο ψάξιμο στο υπολειμματικό γράφημα, με **τυχαία** ουρά προτεραιότητας

Παράδειγμα




Παράδειγμα (συν.)



Ανάλυση Μεθόδου




- Πολυπλοκότητα $O(VEM)=O(|f|E)$
 - Στην χειρότερη περίπτωση, κάθε βήμα θα αυξάνει την χωρητικότητα κατά μία μονάδα.
 - Άρα $|f|$ ψαξίματα μονοπατιού, κόστους $O(V+E)=O(E)$.
 - Επιπλέον, $|f|=O(VM)$ καθώς η τιμή τομής είναι $O(VM)$
 - Το όριο είναι **σφιχτό (tight)**, όπως δείχνει και το διπλανό στιγμιότυπο, και **ψευδοπολυωνυμικό**, γιατί εξαρτάται από την $|f|$
- Άλλο μειονέκτημα:
 - Αστάθεια συγκλίσεως στην τελική ροή, εάν οι χωρητικότητες είναι πραγματικοί αριθμοί







Αλγόριθμοι Edmonds-Karp

- Οι Edmonds-Karp παρατήρησαν πως, εάν τα επαυξητικά μονοπάτια αναζητηθούν
 - είτε βάσει της μέγιστης τιμής ροής
 - είτε βάσει του μικρότερου πλήθους ακμών,τότε η Μέθοδος Ford-Fulkerson γίνεται **πολυωνυμική**

Παράδειγμα Μέγιστης Τιμής Επαυξητικού Μονοπατιού



Παράδειγμα Μέγιστης Τιμής Επαυξητικού Μονοπατιού (συν.)







Ανάλυση





- Το πλήθος των επαυξητικών μονοπατιών είναι $O(E \log M)$, M μέγιστη τιμή χωρητικότητας
 - Έστω ότι η ροή f' έχει τιμή $|f'|$ και $|f|$ είναι η τελική τιμή
 - Υπάρχουν το πολύ E διακριτά επαυξητικά μονοπάτια, συνολικής ροής $|f| - |f'|$
 - Βάσει της αρχής του περιστερώνα, το μέγιστο μονοπάτι θα έχει τιμή **τουλάχιστον** $(|f| - |f'|)/E$
 - Θεωρούμε την ακολουθία των επαυξητικών βημάτων σε υποομάδες των $2E$. Έστω μία υποομάδα $2E$ επαυξητικών βημάτων που δημιουργούν ροές $f'_1, f'_2, f'_3, \dots, f'_i, \dots$ και f' η ροή πριν την έναρξή της. Τότε,
 - Εάν κάθε ένα από αυτά τα βήματα προωθεί ροή τιμής **τουλάχιστον** $|f| - |f'|/2E$, τότε η διαδικασία τερματίζει μετά από $2E$ βήματα, το πολύ, και αυτή είναι η τελευταία υποομάδα που μελετούμε. Διαφορετικά,
 - Εάν υπάρχει έστω και ένα επαυξητικό βήμα, π_i , το i -στο, με τιμή ροής λιγότερη από $(|f| - |f'|)/(2E)$, τότε

$$(|f| - |f'_{i-1}|)/E \leq |f_i| - |f'_{i-1}| < (|f| - |f'|)/(2E) \Rightarrow [(|f| - |f'_{i-1}|)/E] / [(|f| - |f'|)/E] \leq 1/2$$
 - Άρα, στην χειρότερη περίπτωση, μετά από $2E$ βήματα, υποδιπλασιάζεται η τιμή του «βαρύτερου» μονοπατιού
- Χρόνος $O(\log_{E/V} V \log M E(V+E))$, M μέγιστη χωρητικότητα ακμής
 - $V+E$ πράξεις στην ουρά προτεραιότητας, π_i , E/V -σωρός, σε κάθε έναν από τους $E \log M$ υπολογισμούς επαυξητικού μονοπατιού



Παράδειγμα Συντομότερου Επαυξητικού Μονοπατιού



Παράδειγμα Συντομότερου Επαυξητικού Μονοπατιού (συν.)




Παράδειγμα Συντομότερου Επαυξητικού Μονοπατιού (συν.)



Ανάλυση

- **Ορθότητα (Σχεδιάγραμμα)** Στηρίζεται στις κάτωθι παρατηρήσεις:
 - **Πρώτον**, τα συντομότερα μονοπάτια συνεχώς αυξάνουν σε μήκος, και
 - **Δεύτερον**, κάθε ακμή του υπολειμματικού γραφήματος ξαναεμφανίζεται σε συντομότερο μονοπάτι που είναι κατά 2 ακμές μεγαλύτερο από την προηγούμενη φορά:

$$d(u) = d(v) + 1 \geq d'(v) + 1 = d'(u) + 1 + 1 = d'(u) + 2$$




- Άρα, θα χρησιμοποιηθούν συνολικά $VE/2$ επανυζητικά μονοπάτια
- Χρόνος $O(E(VE))=O(VE^2)$

Τεχνική Προροής-Προωθήσεως

- Διαίσθηση

- Γιατί να μην σταλεί με μιας ροή 5 στην κορυφή 4;



- Το $s \rightarrow 4$ θα συμμετείχε μόνο μία φορά, αντί σε 5 διαφορετικά επαυξητικά μονοπάτια, μεγέθους 1

- Τεχνική Προροής-Προωθήσεως

- Προσπαθούμε να οδηγήσουμε σε κορεσμό τις ακμές, διοχετεύοντας όση ροή επιτρέπεται
- Οι ενδιάμεσες κορυφές μπορούν να αποθηκεύουν πλεονάζουσα ροή – χαρακτηρίζονται, τότε, ως *ενεργές (active)*
- Έτσι δημιουργείται μία προσέγγιση ροής, η *προροή*, η οποία θα συγκλίνει στην τελική «κανονική» ροή

Τεχνική Προροής-Προωθήσεως (συν.)

- Προκειμένου η προροή να μετασχηματιστεί σε νόμιμη ροή, πρέπει πρώτα να φθάσει ροή στην καταβόθρα και, κατόπιν, το πλεόνασμα να επιστραφεί στην πηγή
- Δηλαδή, *πρέπει να εξαλειφθούν οι ενεργές κορυφές*. Πώς;
 - Υπολειμματικό γράφημα
 - Συνάρτηση ύψους στο υπολειμματικό γράφημα
- Συνάρτηση ύψους
 - $h(t) = 0$
 - $h(v) \leq h(u) + 1, (v,u) \in E_r$
 - Π.χ., $h \equiv$ απόσταση από καταβόθρα
- Όταν $h(v) = h(u) + 1$, τότε η (v,u) καλείται *νόμιμη*


Ιδιότητες

- Το ύψος μίας κορυφής v δεν ξεπερνά το μήκος της συντομότερης αποστάσεως από την v προς την καταβόθρα t
 - Έστω $v \rightarrow v_1 \rightarrow v_2 \rightarrow \dots \rightarrow t$ το συντομότερο μονοπάτι. Τότε:
$$h(v) \leq h(v_1) + 1 \leq h(v_2) + 2 \leq \dots \leq h(t) + d = 0 + d$$
- Όταν $h(v) > V$, τότε δεν υπάρχει μονοπάτι από την v προς την καταβόθρα t (γιατί;)







Γενικό Σχεδιάγραμμα Αλγορίθμων Προροής-Προωθήσεως

- Αναθέτουμε ύψη βάσει των συντομότερων μονοπατιών προς καταβόθρα
- Φέρουμε σε κορεσμό όλες τις ακμές της πηγής
- Όσο υπάρχουν ενεργές κορυφές, επιλέγουμε μία, έστω v , και
 - είτε σπρώχνουμε ροή μέσω μίας *νόμιμης ακμής* της
 - είτε, εάν δεν υπάρχουν νόμιμες ακμές, υψώνουμε την v , ώστε να είναι κατά *μία μονάδα υψηλότερη* από τον *χαμηλότερό της γείτονα*


Παράδειγμα



Παράδειγμα (συν.)



Παράδειγμα (συν.)



Γιατί δουλεύει;

- Μηχανικό ανάλογο
- Στο υπολειμματικό γράφημα υπάρχει μονοπάτι από κάθε ενεργή κορυφή προς την πηγή, ενώ η πηγή είναι απομονωμένη από την καταβόθρα
 - Πολύ εύκολα, με επαγωγή, ξεκινώντας από το γεγονός πως, αρχικά, οδηγούνται σε κορεσμό αυτές της πηγής 
 - Οι μόνες που «βλέπει» η πηγή, έχουν ύψος $> h(s)$ (αφού της επιστρέφουν ροή) $\Rightarrow$ δεν επικοινωνούν με την καταβόθρα (ιδιότητα ύψους $h(v) \leq h(u) + 1, (v,u) \in E_r$, σταθερό 0)
- Καμμία κορυφή δεν αποκτά ύψος μεγαλύτερο του $2V$
 - Η πηγή έχει ύψος $\leq V$, ενώ κάθε ενεργή κορυφή v απέχει το πολύ $V-2$ ακμές από την s : $v \rightarrow v_1 \rightarrow v_2 \rightarrow \dots \rightarrow s$
$$h(v) \leq h(v_1) + 1 \leq h(v_2) + 2 \leq \dots \leq h(s) + d \leq V + d \leq 2V-2$$
 - Όταν η v καταστεί ανενεργή, το ύψος της είτε είναι το ίδιο είτε κατά ένα μεγαλύτερο από τον χαμηλότερο γείτονά της.

Γιατί δουλεύει; (συν.)

- Όταν τερματίζει:
 - δεν υπάρχουν ενεργές κορυφές
 - η πηγή είναι αποκομμένη από την καταβόθρα
- Άρα
 - δημιουργείται κανονική ροή
 - δεν υπάρχουν επαυξητικά μονοπάτια

Ανάλυση

- Μέσω Συναρτήσεων Δυναμικού (σχεδιάγραμμα)
 - $\Phi = \sum h(v)$, v ενεργή
 - αρχική τιμή $\leq V \times 2V$
 - τελική τιμή 0
 - Πώς μεταβάλλεται το δυναμικό
 - Α' περίπτωση: ύψωση κορυφής κατά $c \Rightarrow \Delta\Phi = c$. Συνολικά, $2V^2 (V \times 2V)$
 - Β' περίπτωση: διοχέτευση ροής.
 - Κορεσμός ακμής:
 $\Delta\Phi = 2V \Rightarrow 2V^2 E$ (τυχόν ενεργοποίηση κορυφής απολήξεως)
 - Ακόρεστη ακμή:
 $\Delta\Phi = -h(v) + h(v) - 1 = -1$ (γίνεται ενεργή γειτονική w , με $h(w) = h(v) - 1$) ή
 $\Delta\Phi = -h(v)$ (ήδη ενεργή η γειτονική w)







Ανάλυση (συν.)

- Σύνοψη
 - Αρχικά:
 $\Phi = 2V^2$
 - Μεταβολές:
 $+(2V^2+2V^2E)$ από αλλαγές ύψους/κορεσμούς ακμών
 - Τελικά:
 $\Phi = 0 \Rightarrow 2V^2+2V^2E = O(V^2E)$ ακόρεστες προωθήσεις
(έκαστη προκαλεί $\Delta\Phi \leq -1$)
- Χρόνος $O(V^2E)$












Τροποποίηση Goldberg-Tarjan

- Επιλογή ενεργής κορυφής για προώθηση ροής μέσω ουράς FiFo
- Όταν επιλεγεί ενεργή κορυφή, προωθείται **συνεχώς** ροή μέσω νομίμων ακμών μέχρι
 - είτε να καταστεί ανενεργή
 - είτε να τελειώσουν οι νόμιμες ακμές, οπότε προσαρμόζεται το ύψος της

Παράδειγμα




Παράδειγμα (συν.)



Ανάλυση

- Πολυπλοκότητα $O(V^2E)$
 - Αποδεικνύεται με συνάρτηση δυναμικού
- Το όριο είναι σφικτό, όπως δείχνει και το κάτωθι σχήμα




Μέγιστα Ταιριάσματα σε Διμελή Γραφήματα

- Ορισμοί



- Κάθε σύνολο ακμών με διαζευγμένα άκρα

- Μέγιστο, εάν δεν υπάρχει άλλο πολυπληθέστερο που να το περιέχει



Επίλυση

- Αναγωγή σε πρόβλημα ροής
 - Προσθήκη πηγής s
 - Προσθήκη καταβόθρας t
 - Μοναδιαία βάρη
- Χρόνος $O((V'+V'')E)$, καθώς
 - το μέγιστο ταίριασμα έχει $(V'+V'')/2$ ακμές, ενώ
 - όλες οι χωρητικότητες ισούνται με 1 $\Rightarrow$ μέγιστη ροή $(V'+V'')/2$



Ροές Ελαχίστου Κόστους

- Ορισμοί


- Με κάθε ακμή e συσχετίζεται και μία τιμή κόστους $b(e)$ ανά μονάδα ροής
- Κόστος μίας ροής f :

$$\sum f(e)b(e)$$

- Μία ροή χαρακτηρίζεται ως *ελαχίστου κόστους* εάν επιδεικνύει το *μικρότερο κόστος μεταξύ όλων των ροών της ίδιας τιμής*
- Μέγιστη ροή ελαχίστου κόστους το ζητούμενο


Επέκταση Υπολειμματικού Γραφήματος

- Αναγκαία η επέκταση του υπολειμματικού γραφήματος, ώστε
 - με κάθε πραγματική ακμή e να σχετίζεται κόστος $b(e)$
 - με κάθε οπισθοακμή, κόστος $-b(e)$ (καθώς τυχόν επιλογή της ελαττώνει το κόστος)



Πρώτη Λύση

- Χρήση επαυξητικών κύκλων αρνητικού κόστους
 - Η ύπαρξή τους σημαίνει δυνατότητα μείωσης του κόστους, χωρίς μεταβολή της τιμής της ροής*




Γιατί δουλεύει;

- Μία ροή είναι ελαχίστου κόστους αν δεν υπάρχει αρνητικός επαυξητικός κύκλος
 - ($\Rightarrow$) Εάν υπάρχει αρνητικός προφανώς μπορεί κανείς να μειώσει το κόστος
 - ($\Leftarrow$) Εάν η f είναι μέγιστη, όχι ελαχίστου κόστους, αλλά με θετικούς κύκλους, τότε επαύξηση κατά μήκος του κύκλου θα μείωνε το κόστος, δίχως να πειραχθεί η τιμή (άτοπο)
- Πολυπλοκότητα $O(BVE)$, B αρχικό κόστος μέγιστης ροής
 - Edmonds-Karp: για αρχική ροή, κόστους B
 - Bellman-Ford: για εντοπισμό B , το πολύ, αρνητικών κύκλων

Δεύτερη Λύση

- Έστω ροή f ελαχίστου κόστους και επαυξητικό μονοπάτι π ελαχίστου κόστους. Τότε η $f': f \rightarrow_{\pi} f'$ είναι ροή ελαχίστου κόστους, με μεγαλύτερη, όμως, τιμή ροής:
 - Εάν η f' δεν είναι ελαχίστου κόστους, τότε πρέπει να υπάρχει αρνητικός κύκλος c , με τουλάχιστον μία κοινή ακμή με την π (γιατί; οι δύο ροές διαφέρουν μόνο στις ακμές $\pi = f' - f$ και, άρα, σε αντίθετη περίπτωση ο κύκλος θα υπήρχε και στην f):



- $b(s \rightarrow v) + b(\delta) + b(u \rightarrow t) < b(s \rightarrow v) + b(v \rightarrow u) + b(u \rightarrow t)$, καθώς
 $b(\delta) + b(u \rightarrow v) < 0 \Rightarrow b(\delta) - b(v \rightarrow u) < 0 \Rightarrow b(\delta) < b(v \rightarrow u)$

Ανάλυση

- Πολυπλοκότητα
 - $O(|f|VE)$: Bellman-ford για τα ΣΜΜΠ, βάσει της b
 - $O(|f|E \log V)$: Εναλλακτικά, για αραιά γραφήματα, Johnson

Συμβολοσειρές

- Σημαντικές λόγω των εφαρμογών τους
 - Επεξεργασία κειμένου
 - Διαδίκτυο
 - Επεξεργασία βιολογικών δεδομένων
 - DNA ως συμβολοσειρές 4 συμβόλων: C (κυτοσίνη), G (γουανίνη), T (θυμίνη), A (αδενίνη)

Ορισμοί


- Σ : αλφάβητο
- Σ^* : όλες οι συμβολοσειρές πεπερασμένου μήκους, συμπεριλαμβανομένης της κενής ϵ
- $|x|$ μήκος συμβολοσειράς x
- $x = \alpha\beta, y = \gamma\delta\epsilon$ συμβολοσειρές
 $xy = \alpha\beta\gamma\delta\epsilon$ συμβολοσειρά συνενώσεώς τους
- $x = \alpha\beta\gamma\delta\epsilon\zeta$
 - Πρόθεμα μήκους i : τα i πρώτα σύμβολα, $\pi x, i=3, \alpha\beta\gamma$
 - Πρόσφυμα μήκους j : τα j τελευταία σύμβολα, $\pi x, j=4, \gamma\delta\epsilon\zeta$

Ακριβές Ταίριασμα Προτύπου (Exact Pattern Matching)

- «Δοθεισών ενός κειμένου T , μήκους n , και ενός προτύπου P , μήκους m , απαιτείται ο εντοπισμός όλων των στιγμιοτύπων του P στο T .»
 - Π.χ. για $T = \alpha\alpha\beta\alpha\beta\beta\alpha\beta\beta\beta\alpha$ και $P = \beta\alpha$, έχουμε
 $\alpha\alpha$ **$\beta\alpha$** $\beta\alpha$ **$\beta\alpha$** $\beta\beta\beta\beta\alpha$
- Εφαρμογές:
 - Κειμενογράφοι
 - αναζήτηση υποδομής σε ακολουθία DNA
 - αναζήτηση λέξεως στα περιεχόμενα μιας σελίδας διαδικτύου

Απλοϊκή Λύση

- Αντιπαράβολή του προτύπου, από όλες τις $n-m+1$ δυνατές θέσεις εκκινήσεως



Κώδικας

Algorithm bruteForcePM(char [] T, char [] P)

Input: Κείμενο T και πρότυπο P

Output: Εντοπισμός του P στο T

```
1. n = T.length; m = P.length;
2. for (i = 1; i = n- m + 1; i++){ // i η τρέχουσα θέση του παραθύρου
3.   j = 1; // δείκτης θέσεως εντός παραθύρου-προτύπου
4.   while ((j <= m) && (T[i+j-1] == P[j]))
5.     j++;
6.   if (j == m +1)
7.     return i;    // βρέθηκε η αρχική θέση του προτύπου
8. }
9. return -1;    // δεν υπάρχει
```

Ανάλυση

- Πολυπλοκότητα $O(nm)$

- Χειρότερη Περίπτωση

Σε κάθε αντιπαραβολή να γίνονται $m-1$ επιτυχημένες συγκρίσεις και να σημειώνεται αποτυχία στην τελευταία. Πχ,

$T = \text{aaaaaaaaaaaaaaaaaaaaaaaaaaaaaaaa}$

$P = \text{aaaaaab}$

$n-m+1$ αντιπαραβολές των m συγκρίσεων
έκαστη

Knuth-Morris-Pratt

- Ανακαλύφθηκε ανεξάρτητα από τους Knuth-Morris και Pratt και, κατόπιν, παρουσιάστηκε ως κοινή εργασία το 1977
- Στηρίζεται στην γραμμική $-O(m)$, δηλ.-επεξεργασία του *προτύπου και όχι του κειμένου*, με σκοπό
 - την εξαγωγή βοηθητικού πίνακα f , και
 - την χρήση της πληροφορίας του f για την μείωση του αριθμού των αντιπαραβολών


Πίνακας Αποτυχίας f

- $f[j] = \text{μέγιστο πρόθεμα τού } P[1..j] \text{ που αποτελεί και πρόσφυμά του}$


1	2	3	4	5	6	7	8	9	10	11
a										
0										

Ποια η χρήση του f

- Εάν έχουν ταιριαστεί οι $j-1$ πρώτοι χαρακτήρες, ενώ υπάρχει διαφορά στον j -στό, τότε
 - μπορούμε να ολισθήσουμε την αντιπαραβολή κατά $j-1-f[j-1]$ θέσεις
 - δεν χάνουμε κανένα στιγμιότυπο!




Παράδειγμα



Τρόπος Υπολογισμού

- Εάν $P[j] = P[f[j-1] + 1]$ τότε $f[j] = f[j-1] + 1$
- Διαφορετικά,
 - είτε είναι το μέγιστο κοινό πρόθεμα του $P[1..f[j-1]]$ ($P[1..f[f[j-1]]]$) συν τον επόμενο χαρακτήρα
 - είτε συνεχίζουμε την αναζήτηση αναδρομικά...



Algorithm kmpPM(char[] T, char[] P)

```
1. n = T.length; m = P.length;
2. int[] f = failureKMP(P, new int[m]);
3. int i = 1, j = 1;
4. while (i < n){
5.   if (P[j] == T[i]){ // ταίριασμα
6.     if (j = m)      // εύρεση!
7.       return i - m;
8.   else{             // μετακίνηση εντός παραθύρου 1 θέση δεξιότερα
9.     i++;
10.    j++;
11.  }
12. else if (j > 1)    // βρέθηκε ταίριασμα εντός παραθύρου
13.   j = f[j-1]        // οπότε γίνεται χρήση της failure function
14. else
15.   i++;
16. }
17. return -1;
18.
19. int[] failureKMP(int[] P, int[] f){
20.   int m = P.length, k = 0;
21.   f[1] = 0;
22.   for (j = 2; j <= m; j++){
23.     while ((k > 0) && (P[k+1] != P[j])) // καθορίζει και την πολυπλοκότητα υπολογισμού
24.       k = f[k]; // P[f[k]+1] ≠ P[j]
25.     if (P[k+1] == P[j])
26.       k++; // κρίσιμο σημείο!!!
27.     f[j] = k;
28.   }
29.   return f;
```

Πολυπλοκότητες


- Ο υπολογισμός της f γίνεται σε χρόνο $O(m)$
 - Η γραμμή 24 του kmpPM καθορίζει την πολυπλοκότητα
- Οι συγκρίσεις είναι μεταξύ n και $2n$ διότι κάθε φορά
 - εάν η σύγκριση είναι επιτυχής, μεταβαίνουμε στον επόμενο χαρακτήρα του κειμένου και ο αντίστοιχος δείκτης i ποτέ δεν μειούται
 - εάν είναι ανεπιτυχής, ολισθαίνουμε τουλάχιστον κατά μία θέση το παράθυρο στο κείμενο, οπότε μία θέση του κειμένου εγκαταλείπεται οριστικά - ο δείκτης j ποτέ δεν μειούται

Boyer-Moore

- Χρησιμοποιείται στο εργαλείο agrep
- Κύρια ιδέα
 - Οι συγκρίσεις να γίνονται *από δεξιά προς τα αριστερά*
 - Όταν σημειώνεται αποτυχία, εφαρμόζονται δύο ευρετικοί κανόνες (heuristics), ώστε βρεθεί η μέγιστη ολίσθηση:
 1. Ευρετικό εμφανίσεως
 2. Ευρετικό ταιριάσματος

Ευρετικό Εμφανίσεως (Occurrence Heuristic)

- Ταίριασμα του χαρακτήρα c του κειμένου που προκάλεσε την αποτυχία με την δεξιότερη εμφάνισή του στο πρότυπο.
- Εάν αυτή είναι δεξιότερα της j , τότε, απλώς, ολισθαίνουμε κατά μία θέση.
- Πολυπλοκότητα $O(\Sigma)$




Παράδειγμα

d'	a	b	c	d	r	$d = m - d'$	a	b	c	d	r
	11	9	5	7	10		0	2	6	4	1


1	2	3	4	5	6	7	8	9	10	11
a	b	r	a	c	a	d	a	b	r	a

Ευρετικό Ταιριάσματος (Match Heuristic)

- Δεξιότερο μέγιστο ταίριασμα των χαρακτήρων του κοινού προσφύματος με διαφορετικό χαρακτήρα-«κεφαλή» από αυτόν που προκάλεσε την διαφορά.



(α)



(β)

Ευρετικό Ταιριάσματος (συν.)

Η υλοποίηση είναι πολύ δύσκολη! Σημειωτέον πως και οι ίδιοι οι ερευνητές είχαν δώσει λάθος κώδικα, τον οποίο διόρθωσε το 1980 ο Rytter!

a	b	r	a	c	a	d	a	b	r	a
a	b	r	a	c	a	d	a	b	r	a
									4	1


a	b	r	a	c	a	d	a	b	r	a
a	b	r	a	c	a	d	a	b	r	a
								12	4	1

Ευρετικό Ταιριάσματος (συν.)

Τελικώς...

a	b	r	a	c	a	d	a	b	r	a
17	16	15	14	13	12	11	13	12	4	1

Μία Εξήγηση των Υπολογισμών




(α)

Έστω ότι υπολογίζουμε «ανάποδα» τον πίνακα KMP, ώστε

- Κάθε θέση $k+1$ μας δίδει την θέση j , όπου προηγείται του προσφύματος x
- $P_j \neq P_{k+1}$, τότε βρήκαμε μία δεξιότερη εμφάνιση του x σε απόσταση $j-k-1$

Μία Εξήγηση των Υπολογισμών (συν.)



- Για την δεύτερη περίπτωση:
 - εάν x είναι το μεγαλύτερο πρόσφυμα που είναι και πρόθεμα, τότε για τις $m - |x|$ πρώτες θέσεις η εικονιζόμενη τοποθέτηση είναι ασφαλής
 - Για τις υπόλοιπες του προσφύματος x , ο υπολογισμός είναι αναδρομικός...

Παράδειγμα

	0	1	2	3	4	5	6	7	8	9	10	11
		a	b	r	a	c	a	d	a	b	r	a
fsuf	7	8	9	10	11	10	11	10	11	11	11	12
match		12	12	12	12	12	12	12	12	12	3	1
match		7	7	7	7	7	7	7	10	10	3	1
+		10	9	8	7	6	5	4	3	2	1	0
match		17	16	15	14	13	12	11	13	12	4	1

- Η πολυπλοκότητα είναι ανάλογη του KMP...

Παράδειγμα Τρεξίματος

d

a	b	c	d	r
0	2	6	4	1

m

a	b	r	a	c	a	d	a	b	r	a
17	16	15	14	13	12	11	13	12	4	1

abrab**abracadabra**

abra**c**adab**ra**

abra**c**adab**ra**
abra**c**adab**ra**

abracadabra

Καλύτερο
το πρώτο

- Την πρώτη φορά έχουμε ολίσθηση βάσει ευρετικού εμφανίσεως $\max\{d[c]=6, m[r]=4\}=6$
- Την δεύτερη, πλήρες ταίριασμα

Πολυπλοκότητα

- Υπολογισμός ευρετικού εμφανίσεως $O(m+|\Sigma|)$ – μειονέκτημα η εξάρτηση από το αλφάβητο
- Υπολογισμός ευρετικού ταιριάσματος
- Συνολικά
 - Χειρότερη Περίπτωση
 $O(nm)$
 - Μέση Περίπτωση υπογραμμικός!
 $O(n \log m/m)$ -δηλαδή, αποφεύγει να διαβάσει όλο το κείμενο

Γενική Συζήτηση

- Στην πράξη, ο Knuth-Morris-Pratt εμφανίζει συμπεριφορά ελάχιστα καλύτερη του απλοϊκού αλγορίθμου
- Ο Boyer-Moore και οι παραλλαγές του είναι η μέθοδος που εφαρμόζεται στην πράξη καίτοι έχει (θεωρητικά) πολύ κακή χειρότερη συμπεριφορά

Ομοιότητα Συμβολοσειρών

- Υπάρχουν εφαρμογές που αιτούν πόσο όμοιες ή ανόμοιες είναι δύο συμβολοσειρές x, y . Π.χ.,
 - Όταν βρίσκουμε τα ορθογραφικά λάθη και προσπαθούμε να βρούμε την σωστή ορθογραφία
 - Προγράμματα-«αράχνες» που βλέπουν πόσο όμοιες είναι οι σελίδες με ήδη καταχωρημένες, ώστε να αποφασίσουν εάν θα τις καταχωρήσουν ή όχι
 - Ακολουθίες DNA, για τις οποίες ομοιότητα σημαίνει και δομική ή λειτουργική ομοιότητα

Μέγιστη Κοινή Υπακολουθία

- Ορισμός υπακολουθίας συμβολοσειράς

$$x = \alpha \beta \gamma \delta \mathbf{2} \tau \delta \mathbf{\lambda}$$

$$x' = \mathbf{\beta 2 \lambda}, \text{ με } i_1 = 2 < i_2 = 5 < i_3 = 8$$

- Παρατηρήστε πως σεβόμαστε την από αριστερά προς τα δεξιά διάταξη των χαρακτήρων
- Έτσι, η $\beta\alpha\delta$ *δεν είναι υπακολουθία*

Μέγιστη Κοινή Υπακολουθία

- Ορισμός

Εάν x, y είναι δύο συμβολοσειρές, τότε η μέγιστη κοινή υπακολουθία τους ορίζεται ως η μεγαλύτερου μήκους υπακολουθία που εμφανίζεται και στις δύο.

– Δεν είναι απαραίτητο να υπάρχει μόνο μία. Π.χ., οι
 $\alpha\beta\epsilon\lambda$ και $\beta\alpha\lambda\epsilon$

έχουν τις εξής μέγιστες, μήκους 2, κοινές
υπακολουθίες:

$\alpha\lambda, \alpha\epsilon, \beta\epsilon, \beta\lambda$

Απλοϊκή Λύση

- Δημιουργία όλων των υπακολουθιών των δύο συμβολοσειρών και σύγκριση μεταξύ τους.
- Κόστος

$$\sum_{i=1}^{\max\{n,m\}} i2^i = O(\max\{n,m\}2^{\max\{n,m\}}), \quad n = |x|, m = |y|$$

Λύση Δυναμικού Προγραμματισμού

- Παρατήρηση

Έστω $x = x[1..n]$, $y = y[1..m]$ οι συμβολοσειρές και $z = z[1..k]$ μία μέγιστη κοινή υπακολουθία τους. Τότε, ισχύει:

$$x[n] \begin{cases} = y[m] \Rightarrow z[k] = x[n], z[1..k-1] = \mu\kappa\upsilon(x[1..n-1], y[1..m-1]) \\ \neq y[m] \text{ και } z[k] \neq x[n], z[1..k] = \mu\kappa\upsilon(x[1..n-1], y[1..m]) \\ \neq y[m] \text{ και } z[k] \neq y[m], z[1..k] = \mu\kappa\upsilon(x[1..n], y[1..m-1]) \end{cases}$$

Λύση Δυναμικού Προγραμματισμού (συν.)

- Επομένως, εάν $c[i,j]$ είναι το μήκος της μέγιστης κοινής υπακολουθίας των $x[1..i]$, $y[1..j]$, τότε ισχύει:

$$c[i,j] = \begin{cases} 0 & i = 0 \text{ ή } j = 0 \\ c[i-1, j-1] + 1 & x[i] = y[j] \\ \max\{c[i, j-1], c[i-1, j]\} & \text{διαφορετικά} \end{cases}$$

Ψευδοκώδικας

Algorithm largestCommonSubSeq(char[] x, char[] y)

```
1. n = x.length; m = y.length;
2. int[][] c = new int[n+1][m+1];
3. int[][] aux = new int[n+1][m+1];
4. for (i = 0; i <= n; i++){ // # O(n)
5.   c[i][0] = 0;
6.   aux[i][0] = NOT X;
7. }
8. for (i = 0; i <= m; i++){ // # O(m)
9.   c[0][i] = 0;
10.  aux[0][i] = NOT Y;
11. }
12. for (i = 1; i <= n; i++) // # O(nm)
13.  for (j = 1; j <= m; j++){
14.    if (x[i] == y[j]) { // ταίριασμα
15.      c[i][j] = c[i-1][j-1]+1;
16.      aux[i][j] = XY;
17.    }
18.    else if (c[i-1][j] >= c[i][j-1]) // το x[i] δεν ανήκει
18.      c[i][j] = c[i-1][j];
20.    aux[i][j] = NOT_X;
21.  }
22.  else {
19.    c[i][j] = c[i][j-1]; // το y[j] δεν ανήκει
20.    aux[i][j] = NOT_Y;
21.  }
22. }
23. return c[n][m];
```

Παράδειγμα

↑ : απόρριψη από BABEΛ

← : απόρριψη από ABEΛ

↖ : ταίριασμα

			A	B	E	Λ
		0	1	2	3	4
B	0	0	←0	←0	←0	←0
	1	↑0	↑0	↖1	←1	←1
	2	↑0	↖1	←1	←1	←1
	3	↑0	↑1	↖2	←2	←2
	4	↑0	↑1	↑2	↖3	←3
	5	↑0	↑1	↑2	↑3	↖4

Ελάχιστη Απόσταση Διαμορφώσεως

- Ορισμοί
 - Πράξεις διαμορφώσεως:
 - $\text{delete}(c)$: διαγραφή του χαρακτήρα c
 - $\text{insert}(c)$: εισαγωγή του χαρακτήρα c
 - $\text{replace}(c,k)$: αντικατάσταση του χαρακτήρα c από τον k

Ελάχιστη Απόσταση Διαμορφώσεως (συν.)

- Πρόβλημα

Δοθεισών δύο συμβολοσειρών x, y , ποια είναι η ελάχιστη ακολουθία πράξεων διαμορφώσεως που μετασχηματίζει την x σε y ;

- Εφαρμογές

- Αποθήκευση εκδοχών αρχείων αποθηκεύοντας μόνο το πλήθος των αλλαγών τους
- Σύγκριση αρχείων
- Σύγκριση ακολουθιών DNA

Παράδειγμα

- 3 πράξεις

$\lambda \textcolor{red}{\epsilon} \acute{\iota} \pi \epsilon \iota \Rightarrow \lambda \acute{\iota} \pi \textcolor{red}{\epsilon} \iota \Rightarrow \lambda \acute{\iota} \pi \textcolor{blue}{\iota} \Rightarrow \lambda \acute{\iota} \pi \eta$
Διαγραφή Διαγραφή Αντικατάσταση

- 4 πράξεις

$\lambda \textcolor{blue}{\epsilon} \acute{\iota} \pi \epsilon \iota \Rightarrow \lambda \acute{\iota} \textcolor{red}{\iota} \pi \epsilon \iota \Rightarrow \lambda \acute{\iota} \pi \textcolor{blue}{\epsilon} \iota \Rightarrow \lambda \acute{\iota} \pi \eta \textcolor{red}{\iota} \Rightarrow \lambda \acute{\iota} \pi \eta$
Αντικατάσταση Διαγραφή Αντικατάσταση Διαγραφή

Παρατήρηση

- Έστω $c[i,j]$ είναι ο ελάχιστος αριθμός διαμορφώσεως των $x[1..i]$, $y[1..j]$. Τότε ισχύει:

$$c[i,j] = \min \begin{cases} c[i-1, j] + 1 & \text{del}(x[i]) & // x[1..i-1] \Rightarrow y[1..j] \\ c[i, j-1] + 1 & \text{ins}(y[j]) & // x[1..i] \Rightarrow y[1..j-1] \\ c[i-1, j-1] + 1 & \text{repl}(x[i], y[j]) & // x[1..i-1] \Rightarrow y[1..j-1] \\ c[i-1, j-1] & x[i] = y[j] & // x[1..i-1] \Rightarrow y[1..j-1] \end{cases}$$

Παράδειγμα

	—	Λ	Ι	Π	Η
—	0	1	2	3	4
Λ	1	0=	←1E	←2E	←3E
E	2	↑1Δ	↖1A	↖2A	↖3A
Ι	3	↑2Δ	↖1=	↖2A	↖3A
Π	4	↑3Δ	↑ 2 Δ	↖1=	← 2E
Ω	5	↑4Δ	↑ 3 Δ	↑ 2Δ	↖2A

Ψευδοκώδικας

Algorithm minEdtDis(char[] x, char[] y)

```
1. n = x.length; m = y.length;
2. for (i = 0; i <= n; i++)      // #  $O(n)$ 
3.   c[i][0] = i;
4. for (i = 0; i <= m; i++)      // #  $O(m)$ 
5.   c[0][i] = i;
6. for (i = 1; i <= n; i++)      // #  $O(nm)$ 
7.   for (j = 1; j <= m; j++)
8.     c[i][j] = min(c[i-1][j]+1, c[i][j-1]+1, (x[i] == y[j] ? c[i-1][j-1] : c[i-1][j-1]+1));
9. return c[n][m];
```

- Πολυπλοκότητα $O(nm)$: ανάλογη, δηλαδή, του μεγέθους του πίνακα c

Αντεστραμμένα Αρχεία

- Αποτελούν την βασική δομή των search engines
- Βασίζονται στην ανάλυση του κειμένου σε λέξεις με:
 - μη διακριτική ικανότητα (άρθρα, σύνδεσμοι κ.ο.κ.), και
 - διακριτική ικανότητα
- Το σύνολο των κοινών, δίχως διακριτική ικανότητα, λέξεων αποτελεί την **τερματική λίστα (stop list)**
- Οι λέξεις με σημασιολογική σπουδαιότητα καλούνται **όροι (terms)** και αποτελούν το **λεξικό**

Περιγραφή

- Με κάθε όρο του λεξικού σχετίζεται μία αντεστραμμένη λίστα με
 - τις εμφανίσεις του όρου –οι δείκτες συνήθως είναι το id του κειμένου–
 - συσχετιζόμενη βοηθητική πληροφορία, π.χ., συχνότητα εμφάνισης
- Οι όροι είναι ταξινομημένοι κατά αλφαβητική σειρά
- Το μέγεθος του λεξικού είναι ΥΠΟΓΡΑΜΜΙΚΟ $O(n^c)$ στο πλήθος n των λέξεων (νόμος Heaps)

Παράδειγμα

- 1 Υπάρχουν δύο τεχνικές ανάλυσης πολυπλοκότητας: η ανάλυση χειρότερης περιπτώσεως και η ανάλυση μέσης περιπτώσεως.
- 2 Σε περίπτωση που η κύρια μνήμη είναι περιορισμένη, χρησιμοποιείται η ιδεατή μνήμη.
- 3 Κύριος λόγος χρήσεως του αλγορίθμου αυτού είναι οι μικρές απαιτήσεις σε μνήμη.

Αλγόριθμος	1	→	3
Ανάλυση	1	→	1
Απαίτηση	1	→	3
Ιδεατή	1	→	2
Κύρια	1	→	2
Κύριος	1	→	3
Λόγος	1	→	3
Μέση	1	→	1
Μικρή	1	→	3
Μνήμη	2	→	2 → 3
Περιορισμένη	1	→	2
Περίπτωση	2	→	1 → 2
Πολυπλοκότητα	1	→	1
Τεχνική	1	→	1
Υπάρχω	1	→	1
Χρήση	1	→	3
Χρησιμοποιώ	1	→	2

Πώς χρησιμεύει

- Μία ερώτηση με ‘και’ (βρες μου όλα τα έγγραφα που περιέχουν ‘πληροφορική’ και ‘πολυτεχνείο’) αντιστοιχεί σε τομή των αντίστοιχων λιστών
- Μία ερώτηση με ‘ή’ (βρες μου όλα τα έγγραφα που περιέχουν ‘πληροφορική’ ή ‘πολυτεχνείο’) αντιστοιχεί σε ένωση των αντίστοιχων λιστών
- Μία ερώτηση με άρνηση (βρες μου όλα τα έγγραφα που δεν περιέχουν την λέξη ‘πληροφορική’) αντιστοιχεί σε αποκλεισμό της αντίστοιχης λίστας
- Μεικτές ερωτήσεις με ‘και’ , ‘ή’ και ‘όχι’ αναλύονται σε αντίστοιχες πράξεις ενώσεως, τομής και συμπλήρωσης (άρνησης) συνόλων με την μορφή λιστών

Δημιουργία

- 1ος τρόπος:
στην κύρια
μνήμη


Αλγόριθμος	→	3	1
Ανάλυση	→	1	3
Απαίτηση	→	3	1
Ιδεατή	→	2	1
Κύρια	→	2	1
Κύριος	→	3	1
Λόγος	→	3	1
Μέση	→	1	1
Μικρός	→	3	1
Μνήμη	→	2	2
Περιορισμένη	→	2	1
Περίπτωση	→	1	2
Πολυπλοκότητα	→	1	1
Τεχνική	→	1	1
Υπάρχω	→	1	1
Χρήση	→	1	3
Χρησιμοποιώ	→	2	1

(α)

Αλγόριθμος	1	→	3	1
Ανάλυση	1	→	1	3
Απαίτηση	1	→	3	1
Ιδεατή	1	→	2	1
Κύρια	1	→	2	1
Κύριος	1	→	3	1
Λόγος	1	→	3	1
Μέση	1	→	1	1
Μικρός	1	→	3	1
Μνήμη	2	→	2	2
Περιορισμένη	1	→	3	1
Περίπτωση	2	→	2	1
Πολυπλοκότητα	1	→	1	2
Τεχνική	1	→	2	1
Υπάρχω	1	→	1	1
Χρήση	1	→	1	1
Χρησιμοποιώ	1	→	2	1
		→	1	1
		→	2	1

(β)

- 2ος τρόπος: Δημιουργία στον σκληρό δίσκο με merge sort!



Κωδικοί Huffman

- Συμπίεση Κειμένου

Η διαδικασία αλλαγής της αναπαραστάσεως ώστε


(α) να καταλαμβάνει μικρότερο χώρο ή να χρειάζεται λιγότερο χρόνο μεταδόσεως και

(β) να είναι δυνατή η **πλήρης** αποκατάσταση της αρχικής μορφής του κειμένου

- Κρίσιμη Παρατήρηση:

Εν αντιθέσει με την εικόνα ή τον ήχο, όπου τυχόν απώλειες (θόρυβος) είναι αποδεκτές, στα κείμενα **δεν είναι ανεκτές οι απώλειες**

Γενική Διαδικασία Κωδικοποίησης - Αποκωδικοποίησης



- Η ανάθεση κωδικών στους χαρακτήρες γίνεται βάσει του πιθανοτικού μοντέλου που διέπει την εμφάνιση των χαρακτήρων του κειμένου

Μέθοδοι Κωδικοποίησης

- **Huffman**

- Η κύρια μέθοδος μέχρι τα τέλη του '70. Την ανακάλυψε ο Huffman στα πλαίσια μίας εργασίας σε μάθημα κατά την διάρκεια των σπουδών του (!)
- Πετυχαίνει συμπίεση 5 μπιτ ανά χαρακτήρα.
- Την χρησιμοποιεί η εντολή pack στο unix.
- Μειονέκτημα ότι πρέπει πρώτα να σαρωθεί όλο το κείμενο.

- **Ziv-Lempel**

- Συμπιέζει 'on-the-fly' βρίσκοντας επαναλαμβανόμενα patterns.
- Πετυχαίνει 4 μπιτ ανά χαρακτήρα.
- Σε αυτήν στηρίζονται τα gzip και compress.

- **Αριθμητικοί Μέθοδοι**


- Συνήθως προτιμούνται για μετάδοση δεδομένων, καθώς πετυχαίνουν κάτι ελάχιστα παραπάνω από 2 μπιτ ανά χαρακτήρα.

Κωδικοί Προθέματος (Prefix Codes)

- **Ορισμός**

Δυαδικές συμβολοσειρές (bit strings) με την *κρίσιμη* ιδιότητα *καμμία να μην αποτελεί πρόθεμα της άλλης*.

- Αναπαρίστανται μέσω Tries, οπότε είναι εύκολη η αποκωδικοποίηση/κωδικοποίηση με διέλευση του δένδρου. Π.χ.,



Κωδικοί Προθέματος (συν.)

- Κόστος δένδρου

$$E(T) = \sum_{c \in T} \mathbf{Prob}[c] \text{len}(c)$$

Άρα ζητούμενο η εύρεση δένδρου T που ελαχιστοποιεί το κόστος. Γιατί;

$$\begin{aligned} E(\text{κειμένου } K) &= \sum_{x \in K} \mathbf{Prob}[x] \text{len}(x) \\ &= |K| \sum_{c \in C} \mathbf{Prob}[c] \text{len}(c), \end{aligned}$$

όπου C το σύνολο των διακεκριμένων χαρακτήρων


Κεντρική Ιδέα

- Στους χαρακτήρες που έχουν μεγάλη συχνότητα εμφάνισης (άρα, έχουν μικρή διακριτική αξία) να δοθούν μικρού μήκους κωδικοί, ενώ στους σπάνιους (με μεγάλη σημασιολογική αξία) να δοθούν μεγαλύτερου μήκους κωδικοί.
- Ο Huffman ανακάλυψε έναν *απλό, βέλτιστο και άπληστο* αλγόριθμο κατασκευής κωδικών


Περιγραφή

- Το αρχικό πρόβλημα κωδικοποιήσεως n χαρακτήρων ανάγεται στην αναδρομική επίλυση ενός προβλήματος $n-1$ χαρακτήρων. Πώς;
 - Με την επιλογή των δύο χαρακτήρων c_i, c_j μικρότερης συχνότητας f_i, f_j , αντίστοιχα, και την αντικατάστασή τους με έναν τεχνητό χαρακτήρα, συχνότητας $f_i + f_j$


Παράδειγμα



Παράδειγμα (συν.)



Παράδειγμα (συν.)



ASCII

```
1101000011100001111100011101110011100100
1110010111101001111000111110110011100001
1010000011101010111110011110010111101001
1110101011101111111100001110111111011111
111001111111001111110011111110010
```

1001**0100**00000**10100**110**110100**11**00001**1110**0100**
1000**0101**1100**011000**11**010101**11**1111**0111**1011**
110010**0001000**10**00011**

Υλοποίηση


Algorithm huffmanCoding(char[] C, int[] F)

```
1. pqueue pq = new pqueue();    // ουρά προτεραιότητας
2. for (i = 0; i < C.length; i++) // αρχικοποίηση με τα φύλλα – χρόνος  $O(n \log n)$ 
3.   pq.insKey(new bNode(new Item(C[i], F[i]), F[i])); // χρόνος  $O(\log n)$ 
4. for (i = 1; i < C.length; i++){ // χρόνος  $O(n \log n)$ 
5.   bNode t = new bNode();      // νέος εσωτερικός κόμβος
6.   x = pq.delMin();            // χρόνος  $O(\log n)$ 
7.   y = pq.delMin();            // χρόνος  $O(\log n)$ 
8.   t.setLeftSon(x);
9.   t.setRightSon(y);
10.  t.setItem(new Item(O, x.Key+y.Key)) // με στοιχείο τον τεχνητό χαρακτήρα O
11.  qp.insKey(t, t.key);          // και συχνότητα το άθροισμά τους – χρόνος  $O(\log n)$ 
12. }
13. return pq.delMin();           // ρίζα του δένδρου ο εναπομείναν κόμβος
```

- **Πολυπλοκότητα:** $O(n \log n)$ με χρήση δυωνυμικής ουράς

Απόδειξη ορθότητας

- Η άπληστη επιλογή οδηγεί σε βέλτιστη λύση· ήτοι, υπάρχει δένδρο κωδικών με τους σπανιότερους χαρακτήρες να είναι αδέρφια



- Η αλλαγή δίδει δένδρο με μικρότερο ή ίσο κόστος με το παλιό καθώς $\mathbf{Prob}[c_i] \leq \mathbf{Prob}[c_k]$ και $\mathbf{Prob}[c_j] \leq \mathbf{Prob}[c_l]$

Απόδειξη ορθότητας (συν.)

- Το δένδρο που προκύπτει συνδυάζοντας την λύση για τους $n-1$ χαρακτήρες είναι βέλτιστο.

Με επαγωγή στο πλήθος n των χαρακτήρων:

- Με την αντικατάσταση, προκύπτει ένα στιγμιότυπο $n-1$ χαρακτήρων, όπου ο τεχνητός χαρακτήρας x έχει βάθος d_x , βέλτιστου -βάσει επαγωγής- κόστους $E(T_{n-1})$
- Με την τοποθέτηση των δύο χαρακτήρων σε βάθος d_x+1 , προκύπτει δένδρο κόστους:

$$E(T_n)=E(T_{n-1})+\mathbf{Prob}[c_i]+\mathbf{Prob}[c_j]$$

- Αυτό είναι βέλτιστο, γιατί:
 - Εάν δεν ήταν, τότε υπάρχει κάποιο άλλο με καλύτερο κόστος, όπου τα c_i, c_j έχουν μέγιστο βάθος.
 - Αντικαθιστώντας τα με ένα τεχνητό χαρακτήρα, προκύπτει στιγμιότυπο για $n-1$ χαρακτήρες με καλύτερη λύση (άτοπο)