

Πιθανοτική ανάλυση και
τυχαιοκρατικοί
αλγόριθμοι

Πιθανοτική ανάλυση και τυχαιοκρατικοί αλγόριθμοι

ΟΔΗΓΟΣ ΠΡΟΣΛΗΨΗΣ (n)

- 1 βέλτιστος = 0 // ο υποψήφιος υπ' αριθμ. 0 είναι ένας εικονικός υποψήφιος χωρίς κανένα προσόν
- 2 για $i = 1$ έως n
- 3 εξετάζουμε τον υποψήφιο i
- 4 αν ο υποψήφιος i είναι καταλληλότερος από τον βέλτιστος
- 5 βέλτιστος = i
- 6 προσλαμβάνουμε τον υποψήφιο i

- c_i : η εξέταση ενός υποψηφίου έχει χαμηλό κόστος, έστω c_i ,
- c_h : το κόστος c_h της πρόσληψης είναι αρκετά υψηλότερο
- Το συνολικό κόστος που προκύπτει από τον αλγόριθμο είναι $O(c_i n + c_h m)$.
- Χειρότερη περίπτωση : $O(nc_h)$ – όταν όλοι οι υποψήφιοι έρχονται με αυστηρώς αύξουσα σειρά ποιότητας.
- Σε αυτό το είδος του προβλήματος, είναι λογικό να αναμένουμε ότι οι υποψήφιοι δεν θα έρχονται πάντα με αύξουσα σειρά ποιότητας.
- Είναι πιο λογικό να θεωρήσουμε τη μέση περίπτωση.

Πιθανοτική ανάλυση

- Πιθανοτική ανάλυση
 - Η χρήση των πιθανοτήτων στην ανάλυση των προβλημάτων
 - Πρέπει να γνωρίζουμε ή να κάνουμε υποθέσεις σχετικά με την κατανομή της εισόδου.
 - Έπειτα, αναλύουμε τον αλγόριθμο, υπολογίζοντας το χρόνο εκτέλεσης στη μέση περίπτωση, όπου παίρνουμε ένα μέσο όρο ως προς όλες τις πιθανές εισόδους.
 - Προσοχή:
 - Για κάποια προβλήματα, δεν μπορούμε να βρούμε μια ρεαλιστική κατανομή για τις εισόδους του προβλήματος.
 - Σε αυτή την περίπτωση, δεν μπορούμε να χρησιμοποιήσουμε πιθανοτική ανάλυση.

Πιθανοτική Ανάλυση

- Για το πρόβλημα της πρόσληψης, θεωρούμε ότι οι υποψήφιοι έρχονται με τυχαία διάταξη.
- Καταχώρησε μία τάξη (rank) σε κάθε υποψήφιο
- $\text{rank}(i)$ δηλώνει τη θέση του υποψήφιου i στην τελική κατάταξη και είναι ένας μοναδικός ακέραιος στο εύρος 1 και n .
- Η λίστα $\langle \text{rank}(1), \text{rank}(2), \dots, \text{rank}(n) \rangle$ είναι μία μετάθεση των αριθμών $\langle 1, 2, \dots, n \rangle$.
- Οι υποψήφιοι έρχονται με τυχαία σειρά
 - = Η λίστα των τάξεων είναι εξίσου πιθανόν να είναι μία από της $n!$ μεταθέσεις.
- Ισοδύναμα, οι τάξεις σχηματίζουν μία **ομοιόμορφη τυχαία μετάθεση**: κάθε μία από τις $n!$ πιθανές μεταθέσεις εμφανίζονται με την ίδια πιθανότητα.

Πιθανοτική Ανάλυση

- Προκειμένου να χρησιμοποιήσουμε την πιθανοτική ανάλυση, θα πρέπει να γνωρίζουμε κάτι σχετικά με την κατανομή της εισόδου.
- Όμως, σε πολλές περιπτώσεις, πολύ λίγα είναι γνωστά για την κατανομή εισόδου.
- Ακόμα και αν εμείς γνωρίζουμε κάτι σχετικά με την κατανομή, μπορεί να μην είμαστε σε θέση να την εκφράσουμε με ένα μοντέλο.
- Παρόλα αυτά, μπορούμε να χρησιμοποιήσουμε την τυχαιότητα και τις πιθανότητες με τη μετατροπή της συμπεριφοράς ενός τμήματος του αλγορίθμου σε τυχαίο.

Τυχαιοκρατικός Αλγόριθμος

- Για το πρόβλημα της πρόσληψης:
 - Αντί να βασιζόμαστε στο να έρχονται οι υποψήφιοι με τυχαία σειρά, έχουμε τον έλεγχο της διαδικασίας και επιβάλλουμε μία τυχαία διάταξη.
 - Το πρακτορείο εύρεσης εργασίας μας στέλνει προκαταβολικά τη λίστα όλων των n υποψηφίων
 - Κάθε μέρα, διατάσσουμε με τυχαίο τρόπο τη λίστα αυτή πριν τις συνεντεύξεις.

RANDOMIZED-HIRE-ASSISTANT(n)

```
1  randomly permute the list of candidates
2  best = 0           // candidate 0 is a least-qualified dummy candidate
3  for  $i = 1$  to  $n$ 
4      interview candidate  $i$ 
5      if candidate  $i$  is better than candidate best
6          best =  $i$ 
7          hire candidate  $i$ 
```

Τυχαιοκρατικός Αλγόριθμος

- Τι κάνει ένα αλγόριθμο τυχαιοκρατικό;
 - Ένας αλγόριθμος είναι τυχαιοκρατικός αν η συμπεριφορά του προσδιορίζεται όχι μόνο από την είσοδο του αλλά από τις τιμές που παράγονται από μία γεννήτρια τυχαίων αριθμών.
 - $RANDOM(a, b)$ επιστρέφει ένα ακέραιο αριθμό r , όπου $a \leq r \leq b$ και κάθε μία από τις $b - a + 1$ πιθανές τιμές της r είναι εξίσου πιθανές.
 - Μία κλήση στη $RANDOM(3, 7)$ επιστρέφει ένα από τα 3, 4, 5, 6, or 7, κάθε ένα με πιθανότητα $1/5$.
 - Στην πράξη, $RANDOM$ υλοποιείται με **μία γεννήτρια ψευδοτυχαίων αριθμών**, η οποία είναι μία ντετερμινιστική μέθοδος για την παραγωγή αριθμών που φαίνονται στατιστικά τυχαίοι.

Δείκτριες τυχαίες μεταβλητές

- Οι δείκτριες τυχαίες μεταβλητές είναι ένας εύχρηστος τρόπος για μετατροπή μεταξύ πιθανοτήτων και αναμενόμενης τιμής.
- Δοθέντος ενός δειγματοχώρου S και ενός γεγονότος A , η δείκτρια τυχαία μεταβλητή που σχετίζεται με το συμβάν A ορίζεται ως:

$$I\{A\} = \begin{cases} 1 & \text{εάν προκύψει } A, \\ 0 & \text{εάν δεν προκύψει } A. \end{cases}$$

Π.χ. $S = \{H, T\}$, $P(H) = P(T) = 1/2$,

- Η δείκτρια τυχαία μεταβλητή X_H αντιστοιχεί στο γεγονός να φέρουμε κορώνα στη ρίψη του κέρματος

$$\begin{aligned} X_H &= I\{H\} \\ &= \begin{cases} 1 & \text{if } H \text{ occurs,} \\ 0 & \text{if } T \text{ occurs.} \end{cases} \end{aligned}$$

Δείκτριες τυχαίες μεταβλητές

Το αναμενόμενο πλήθος των κορωνών σε ένα γύρισμα κέρματος = αναμενόμενη τιμή της X_H

$$\begin{aligned} E[X_H] &= E[I\{H\}] \\ &= 1 \cdot P(H) + 0 \cdot P(T) \\ &= 1 \cdot (1/2) + 0 \cdot (1/2) \\ &= 1/2 \end{aligned}$$

- Έτσι, το αναμενόμενο πλήθος των κορωνών για ένα γύρισμα είναι $1/2$.
- Επομένως αν $X_i = I\{\text{το νόμισμα } i \text{ είναι κορώνα}\}$ τότε
$$X = X_1 + X_2 + X_3 + X_4 + \dots + X_n \text{ (πλήθος κορωνών για } n \text{ ρίψεις)}$$
- Επομένως, $E(X) = E(X_1) + E(X_2) + E(X_3) + E(X_4) + \dots + E(X_n) = n/2$

Δείκτριες τυχαίες μεταβλητές

Λήμμα. Δοθέντος ενός δειγματοχώρου S και ενός γεγονότος A στο S , έστω $X_A = I \{A\}$. Τότε $E [X_A] = P(A)$.

Απόδειξη

$$\begin{aligned} E [X_A] &= E [I \{A\}] \\ &= 1 \cdot P(A) + 0 \cdot P(\bar{A}) \\ &= P(A), \end{aligned}$$

όπου \bar{A} δηλώνει το $S - A$, το συμπλήρωμα του A .

Η ανάλυση του προβλήματος πρόσληψης με τη χρήση των δείκτριων τυχαίων μεταβλητών

- Έστω X μία τυχαία μεταβλητή της οποίας η τιμή ισούται με το πλήθος των φορών που προσλαμβάνουμε ένα νέο άτομο.

$$E[X] = \sum_{x=1}^n x \Pr\{X = x\} \quad \begin{aligned} X_i &= I\{\text{candidate } i \text{ is hired}\} \\ &= \begin{cases} 1 & \text{if candidate } i \text{ is hired,} \\ 0 & \text{if candidate } i \text{ is not hired,} \end{cases} \end{aligned}$$

$$E[X_i] = \Pr\{\text{ο υποψήφιος } i \text{ προσλαμβάνεται}\}$$

$$E[X_i] = 1/i \quad X = X_1 + X_2 + X_3 + X_4 + \dots + X_n$$

$$\begin{aligned} E[X] &= E\left[\sum_{i=1}^n X_i\right] \\ &= \sum_{i=1}^n E[X_i] \\ &= \sum_{i=1}^n 1/i \\ &= \ln n + O(1) \end{aligned}$$

Τυχαία μετάθεση της εισόδου

PERMUTE-BY-SORTING(*A*)

```
1 n = A.length
2 let P[1..n] be a new array
3 for i = 1 to n
4     P[i] = RANDOM(1, n3)
5 sort A, using P as sort keys
```

RANDOMIZE-IN-PLACE(*A*)

```
1 n = A.length
2 for i = 1 to n
3     swap A[i] with A[RANDOM(i, n)]
```

Ανάλυση της Permute-By-Sorting

- Για $i = 1, 2, \dots, n$, έστω E_i το ενδεχόμενο το στοιχείο $A[i]$ να λάβει τον i -οστό μικρότερο αριθμό προτεραιότητας.
- Ο στόχος: να υπολογίσουμε την πιθανότητα να συμβεί το ενδεχόμενο E_i , για όλα τα i , η οποία είναι

$$\begin{aligned} \Pr \{E_1 \cap E_2 \cap E_3 \cap \dots \cap E_{n-1} \cap E_n\} &= \Pr \{E_1\} \cdot \Pr \{E_2 | E_1\} \cdot \\ &\Pr \{E_3 | E_2 \cap E_1\} \cdot \Pr \{E_4 | E_3 \cap E_2 \cap E_1\} \cdot \dots \\ &\Pr \{E_i | E_{i-1} \cap E_{i-2} \cap \dots \cap E_1\} \cdot \dots \cdot \Pr \{E_n | E_{n-1} \cap \dots \cap E_1\}. \end{aligned}$$

$$\begin{aligned} \Pr \{E_1 \cap E_2 \cap E_3 \cap \dots \cap E_{n-1} \cap E_n\} &= \left(\frac{1}{n}\right) \left(\frac{1}{n-1}\right) \dots \left(\frac{1}{2}\right) \left(\frac{1}{1}\right) \\ &= \frac{1}{n!}, \end{aligned}$$

Permute-By_Sorting

- Η πιθανότητα όλες οι προτεραιότητες να είναι διαφορετικές:
- $P_{\text{diff}} = 1 * (1 - 1/n^3)(1 - 2/n^3)(1 - 3/n^3) \dots (1 - (n-1)/n^3) \geq (1 - n/n^3) \dots (1 - n/n^3) = (1 - 1/n^2)^n \geq 1 - 1/n$

Η τελευταία ανισότητα ισχύει γιατί $(1-a)^n \geq 1 - n*a$ ($a < 1$) (Η συνάρτηση $f(x) = (1-a)^x + ax - 1$ είναι αύξουσα για $x \geq 1$ και $f(1) = 0$)
- Αν προκύψουν ίδιες οι προτεραιότητες, ξανατρέχουμε τον αλγόριθμο.
- Πόσες επαναλήψεις χρειάζονται για να προκύψουν μοναδικές προτεραιότητες;
- Η πιθανότητα να χρειαστούν k επαναλήψεις:
$$P_k = (1 - P_{\text{diff}})^{k-1} P_{\text{diff}}$$
 (γεωμετρική κατανομή)
- Επομένως, το μέσο πλήθος προσπαθειών είναι $1 / P_{\text{diff}} \leq 1 / (1 - 1/n) = n / (n-1)$

Τυχαία μετάθεση της εισόδου

- Ανάλυση της Randomize-In-Place
- Θα αποδείξουμε την αναλλοίωτη συνθήκη:
- Ακριβώς πριν από την i -οστή επανάληψη, για κάθε δυνατή $(i-1)$ -μετάθεση των n στοιχείων, η υποσυστοιχία $A[1 \dots i-1]$ έχει πιθανότητα $(n-i+1)!/n!$ να περιέχει αυτήν την $(i-1)$ -μετάθεση.
- Έστω E_1 το ενδεχόμενο οι πρώτες $i-1$ επαναλήψεις να έχουν τη συγκεκριμένη $(i-1)$ -μετάθεση (x_1, \dots, x_{i-1}) στην υποσυστοιχία $A[1 \dots i-1]$
- E_2 το ενδεχόμενο το στοιχείο που θα τοποθετηθεί στη θέση $A[i]$ με την i -οστή επανάληψη να είναι το x_i .
- $\Pr \{E_2 \cap E_1\} = \Pr \{E_2 \mid E_1\} \Pr \{E_1\} = 1/(n-i+1) * (n-i+1)!/n! = (n-i)!/n! .$

Το άμεσης απόκρισης πρόβλημα της πρόσληψης

ON-LINE-MAXIMUM(k, n)

```
1  bestscore =  $-\infty$ 
2  for  $i = 1$  to  $k$ 
3      if  $score(i) > bestscore$ 
4          bestscore =  $score(i)$ 
5  for  $i = k + 1$  to  $n$ 
6      if  $score(i) > bestscore$ 
7          return  $i$ 
8  return  $n$ 
```

S : το ενδεχόμενο να επιλέξουμε τον καταλληλότερο υποψήφιο

S_i : το ενδεχόμενο να επιλέξουμε τον καταλληλότερο όταν αυτός είναι ο i -οστός.

$$\Pr \{S\} = \sum_{i=k+1}^n \Pr \{S_i\} .$$

B_i : το ενδεχόμενο ο καλύτερος υποψήφιος να βρίσκεται στη θέση i

O_i : το ενδεχόμενο να μην επιλεγεί κανείς υποψήφιος από τις θέσεις $k + 1$ έως $i - 1$

$$\Pr \{S_i\} = \Pr \{B_i \cap O_i\} = \Pr \{B_i\} \Pr \{O_i\} . \quad \Pr \{B_i\} = 1/n \quad \Pr \{O_i\} = k/(i-1)$$

Το άμεσης απόκρισης πρόβλημα της πρόσληψης

$$\begin{aligned}\Pr\{S\} &= \sum_{i=k+1}^n \Pr\{S_i\} \\ &= \sum_{i=k+1}^n \frac{k}{n(i-1)} \\ &= \frac{k}{n} \sum_{i=k+1}^n \frac{1}{i-1} \\ &= \frac{k}{n} \sum_{i=k}^{n-1} \frac{1}{i}.\end{aligned}$$

$$\int_k^n \frac{1}{x} dx \leq \sum_{i=k}^{n-1} \frac{1}{i} \leq \int_{k-1}^{n-1} \frac{1}{x} dx .$$

$$\frac{k}{n}(\ln n - \ln k) \leq \Pr\{S\} \leq \frac{k}{n}(\ln(n-1) - \ln(k-1)) ,$$

$k = n/e$ για μέγιστη πιθανότητα πρόσληψης του καλύτερου

Το πρόβλημα του συλλέκτη κουπονιών

- Άλμπουμ που πρέπει να συμπληρώσετε b αυτοκόλλητα.
- Κάθε φακελάκι που αγοράζετε περιέχει ένα αυτοκόλλητο και έστω ότι περιέχει ένα από τα b αυτοκόλλητα με την ίδια πιθανότητα.
- Πόσα φακελάκια πρέπει να αγοράσουμε για να συμπληρώσουμε το άλμπουμ.
- Το πρόβλημα μπορεί να ειπωθεί ως ένα πρόβλημα σφαιρών και δοχείων (balls and bins)
- Συγκεκριμένα, αν έχουμε b δοχεία, πόσες σφαίρες πρέπει να ρίξουμε για να μην έχουμε άδεια δοχεία;
- Οι ρίψεις γίνονται με τυχαίο τρόπο, κάθε σφαίρα μπορεί να καταλήξει σε οποιαδήποτε δοχείο με την ίδια πιθανότητα.

Το πρόβλημα του συλλέκτη κουπονιών (Συν.)

- Η διαδικασία χωρίζεται σε b φάσεις.
- Η 1^η φάση τελειώνει με την πρώτη ρίψη (άρα 1 δοχείο μη άδειο)
- Η 2^η φάση τελειώνει όταν ένα άδειο δοχείο δεχθεί την πρώτη σφαίρα (2 δοχεία μη άδεια)
- Η i -οστη φάση τελειώνει όταν ένα άδειο δοχείο δεχθεί την πρώτη σφαίρα (i δοχεία μη άδεια)
- Έστω n_i οι ρίψεις που χρειάζονται για να ολοκληρωθεί η i -οστη φάσεις. Ισχύει

$$E[n_i] = \frac{b}{b - i + 1}$$

Γεωμετρική κατανομή

Το πρόβλημα του συλλέκτη κουπονιών (Συν.)

- Το συνολικό πλήθος ρίψεων:

$$n = n_1 + n_2 + \dots + n_b$$

- Ισχύει

$$\begin{aligned} \mathbb{E}[n] &= \mathbb{E} \left[\sum_{i=1}^b n_i \right] \\ &= \sum_{i=1}^b \mathbb{E}[n_i] \\ &= \sum_{i=1}^b \frac{b}{b-i+1} \\ &= b \sum_{i=1}^b \frac{1}{i} \\ &= b(\ln b + O(1)) \end{aligned}$$