

# Πιθανότητες και Αλγόριθμοι

---

**Δημήτρης Φωτάκης**

Σχολή Ηλεκτρολόγων Μηχανικών  
και Μηχανικών Υπολογιστών

Εθνικό Μετσόβιο Πολυτεχνείο



# Πιθανοτικοί Αλγόριθμοι

---

- **Πιθανοτικός αλγόριθμος** κάνει **τυχαίες επιλογές** και εξαρτά **εξέλιξή του** από αυτές.
  - **Κατανομή πιθανότητας** πάνω σε ντετερμινιστικούς αλγόριθμους.
- Πλεονεκτήματα πιθανοτικών αλγόριθμων:
  - **Απλότητα** και κομψότητα (π.χ. quickselect, primality).
  - Συνήθως **ταχύτεροι** από ντετερμινιστικούς.
  - Όταν έχουμε μερική γνώση, περιορισμένη μνήμη, κλπ., πρακτικά αποτελούν **μόνη αποδοτική λύση**.
- Μειονεκτήματα:
  - **Λάθος** απάντηση (με μικρή πιθανότητα).
  - Κυμαινόμενος **χρόνος** εκτέλεσης.
  - Δύσκολο **debugging**.

# Πώς τα Καταφέρνουν;

---

- Εκμεταλλεύονται «εργαλεία» της πιθανότητας.
- «Αδυνατίζει» (και γίνεται πιο ρεαλιστική) η χειρότερη περίπτωση (π.χ. quicksort).
- Τυχαία δειγματοληψία: αντιπροσωπευτικό δείγμα και λύση (π.χ. clustering, sublinear algs).
- Ικανό πλήθος πιστοποιητικών (βλ. property testing).
- Τυχαία μοιρασιά εργασιών: ισορροπημένη και με ελάχιστο κόστος (υπολογιστικό, επικοινωνιακό).
- Fingerprinting και hashing.
- «Σπάσιμο» συμμετρίας (π.χ. Ethernet, leader election).
- Προσομοίωση διαδικασιών και rapid mixing.

# Γινόμενο Πολυωνύμων

---

- Πολυώνυμο  $P_1(x)$  και  $P_2(x)$  βαθμού  $d$ , και πολυώνυμο  $P_3(x)$  βαθμού  $2d$ , όλα ορισμένα σε field  $F$ .
- Έλεγχος αν  $P_1(x) \times P_2(x) = P_3(x)$ 
  - ... σε χρόνο (σημαντικά) μικρότερο του πολλαπλασιασμού;
- Ελέγχουμε αν  $Q(x) = P_1(x) \times P_2(x) - P_3(x)$  είναι (ταυτ.) 0.
  - Έστω  $Q(x)$  βαθμού  $2d$  και όχι (ταυτοτικά) 0.  
Τότε,  $\Pr_{r \in F}[Q(r) = 0] \leq 2d/|F|$ .
  - Για  $|F| = 200d$  και 3 ανεξ. δείγματα, πιθαν. λάθους  $\leq 10^{-6}$ .
  - Χρόνος πολ/μού:  $\Theta(d^2)$  (ή  $\Theta(d \log d)$ ). Χρόνος ελέγχου:  $\Theta(d)$ .
- Επεκτείνεται σε πολυώνυμο **πολλών μεταβλητών**, όπου αντίστοιχη πιθανότητα ορίζεται με **συνολικό βαθμό**.
  - Θεώρημα **Schwartz-Zippel**.

# Γινόμενο Πινάκων

---

- Δίνονται  $A, B, C$  πίνακες  $n \times n$ .
  - Έλεγχος αν  $AB = C$  σε χρόνο  $O(n^2)$ .
- Τυχαίο διάνυσμα  $r \in \{0, 1\}^n$ . Απαντ. **ΝΑΙ** αν  $A(Br) = Cr$ .
  - Ισοδύναμα αν  $Dr = 0$ , όπου  $D = (AB - C)$ .
  - Αν  $D \neq 0$ ,  $D$  έχει μη μηδενικά στοιχεία.  
Χβτγ., κάποια στην  $1^{\text{η}}$  γραμμή του  $D$ , ένα στην  $1^{\text{η}}$  στήλη.
  - Για κάθε επιλογή των  $r_2, \dots, r_n$ ,  
υπάρχει μια (το πολύ) επιλογή για το  $r_1$  τ.ω.  $\sum_{j=1}^n D_{1j}r_j = 0$
  - Άρα πιθανότητα λάθους  $\leq 1/2$ .
  - Με π.χ. 30 ανεξάρτητες επαναλήψεις, πιθαν. λάθους  $< 10^{-6}$ .

# Γινόμενο Πινάκων: Εργαλείο


---

- Ανάλυση βασίζεται σε **αρχή αναβολής τυχαίων αποφάσεων** (principle of deferred decisions):
  - «Φιξάρουμε» μέρος των **τυχαίων** επιλογών (συνήθως σε **αυθαίρετες** τιμές).
  - Υπολογίζουμε **πιθανότητα**, δεδομένων αυτών των τιμών.
    - Τεχνικά, υπολογίζουμε την **πιθανότητα υπό συνθήκη**.  
Επειδή ισχύει για αυθαίρετη συνθήκη, **ισχύει χωρίς συνθήκη**.
- Γενικότερα, έστω  $E_1, \dots, E_n$  μια **διαμέριση** του δειγματοχώρου σε γεγονότα. Τότε:

$$\Pr[B] = \sum_{i=1}^n \Pr[B \cap E_i] = \sum_{i=1}^n \Pr[B|E_i] \Pr[E_i]$$


# Ελάχιστη Τομή

- Μη κατευθυνόμενο συνεκτικό **πολυγράφημα**  $G(V, E)$ .
  - Πολλαπλές ακμές, όχι χωρητικότητες / βάρη.
- **Τομή**: διαμέριση κορυφών  $(S, V \setminus S)$  με  $\emptyset \neq S \subset V$ .
  - Σύνολο ακμών που **αφαίρεσή** τους δημιουργεί τουλ. 2 συνεκτικές **συνιστώσες**.
  - Μέγεθος τομής  $b(S, V \setminus S) = |\{\{u, v\} \in E : u \in S, v \notin S\}|$
- Πρόβλημα: υπολογισμός μιας **ελάχιστης τομής**.
  - Λύνεται σε χρόνο  $O(n^4)$  με διαδοχικές εφαρμογές αλγόριθμου μέγιστης ροής.
  - Υπάρχουν εξειδικευμένοι αλγόριθμοι με χρόνο  $O(n^3)$ .



# Σύμπτυξη Κορυφών


- **Σύμπτυξη** κορυφών  $u$  και  $v$ :
  - Αντικατάσταση  $u, v$  από μία **νέα κορυφή  $uv$** .
  - Κάθε ακμή  $\{x, u\} / \{x, v\}$  αντικαθίσταται από ακμή  $\{x, uv\}$ .
  - Ακμές  $\{u, v\}$  παραλείπονται.
  - Διαδοχικές συμπτύξεις κορυφών 1, 2 και 12, 3.
- **Τομή** σε γράφημα **μετά από διαδοχικές συμπτύξεις** αντιστοιχεί σε **τομή σε αρχικό** γράφημα.
  - Λειτουργία σύμπτυξης **δεν** μειώνει ελάχιστη τομή.






# Πιθανοτικός Αλγόριθμος [Karger, 93]

- **Ενόσω** το γράφημα που απομένει έχει  $> 2$  κορυφές:
  - Διάλεξε μια **τυχαία ακμή**  $\{u, v\}$ .
  - Αντικατέστησε γράφημα με αυτό που προκύπτει από **σύμπτυξη** κορυφών  $u$  και  $v$ .
- **Ακμές τομής** αυτές **μεταξύ 2 κορυφών** που απομένουν.
- **Τομή** ορίζεται από **κορυφές που συμπτύχθηκαν στις 2 κορυφές** που απομένουν.




# Παράδειγμα

- Αρχικές συμπτώξεις 1, 2, και 12, 3.
  - Σύμπτυξη 123, 4.
  - Σύμπτυξη 5, 4.



# Πιθανοτικός Αλγόριθμος [Karger, 93]

- Βασικές ιδιότητες:
  - Πάντα **τερματίζει** έπειτα από  $n - 2$  συμπτώξεις.
  - Υπολογίζει μία τομή, μπορεί **όχι** ελάχιστη.
  - Ποια πιθανότητα  $p$  να καταλήξει σε ελάχιστη τομή;
  - Αν  $p$  όχι αμελητέα, **μεγαλώνει γρήγορα με επαναλήψεις**.
  - Αν  $p \geq 2/n^2$ , πιθανότητα τουλ. μία από  $n^2 \ln n$  επαναλήψεις να καταλήξει σε ελάχιστη τομή  $\geq 1 - 1/n^2$ .
- Έστω ελάχιστη τομή  $C = \{e_1, \dots, e_k\}$  μεγέθους  $k$ .
  - Αλγ. επιστρέφει  $C$  ανν καμία από ακμές  $C$  δεν επιλεγεί για σύμπτυξη.



# Πιθανότητα Επιτυχίας

- Συγκεκριμένη ελάχιστη τομή  $C = \{e_1, \dots, e_k\}$  μεγέθους  $k$ .
  - Πιθανότητα **καμία** από ακμές  $C$  **δεν** επιλέγεται για σύμπτυξη.
  - Ελάχιστος βαθμός κορυφής  $\geq$  ελάχιστη τομή.
  - $G(V, E)$  έχει **ελάχιστο βαθμό** κορυφής  $\geq k$ .
    - $G$  έχει **#ακμών**  $\geq nk/2$ .
    - Πιθανότητα **δεν** επιλέγεται ακμή του  $C$  στην **1<sup>η</sup>** σύμπτυξη: 
$$p_1 \geq \frac{\frac{nk}{2} - k}{\frac{nk}{2}} = \frac{n-2}{n}$$
    - Μετά από  $t$  συμπτώξεις, γράφημα έχει **ελάχιστο βαθμό**  $\geq k$ .
      - **#ακμών**  $\geq (n-t)k/2$ .
      - Πιθανότητα **δεν** επιλέγεται ακμή  $C$  του **ούτε** στην **(t+1)<sup>η</sup>** σύμπτυξη: 
$$p_{t+1} \geq \frac{\frac{(n-t)k}{2} - k}{\frac{(n-t)k}{2}} = \frac{n-t-2}{n-t}$$

# Πιθανότητα Επιτυχίας

---

- Συγκεκριμένη ελάχιστη τομή  $C = \{e_1, \dots, e_k\}$  μεγέθους  $k$ .
  - Πιθανότητα **καμία** από ακμές  $C$  **δεν επιλέγεται** για σύμπτυξη:

$$p = p_1 \cdot p_2 \cdots p_{n-2} \geq \frac{n-2}{n} \cdot \frac{n-3}{n-1} \cdot \frac{n-4}{n-2} \cdots \frac{2}{4} \cdot \frac{1}{3} = \frac{2}{n(n-1)}$$

- Άρα  $p \geq 2/n^2$ , και πιθανότητα τουλ. **μία** από  $n^2 \log n$  επαναλήψεις να καταλήξει σε **ελάχιστη τομή**  $\geq 1 - 1/n^2$ .
  - Χρόνος εκτέλεσης  $O(n^2)$  / επανάληψη.
  - Συνολικός χρόνος  $O(n^4 \log n)$ .

# Χρόνος Εκτέλεσης

---

- Όμως (σχετικά) μικρή πιθανότητα αποτυχίας στις πρώτες μισές συμπτώξεις!
  - Π.χ. πιθανότητα να μην συμπτυχθεί καμία ακμή  $C$  στις πρώτες  $(n-3)/2$  συμπτώξεις  $\geq 1/4$ .
  - «Ακριβές» συμπτώξεις είναι «επιτυχημένες».
- Αναδρομική υλοποίηση σε φάσεις:
  - Εκτέλεση βασικού αλγόριθμου για  $n/2$  συμπτώξεις 4 φορές.
  - Συνεχίσουμε αναδρομικά για καθένα από τα αποτελέσματα.
  - Χρόνος εκτέλεσης:  $O(n^2 \log n)$  ( $O(\log n)$  επίπεδα,  $O(n^2)$  / επίπεδο)
  - Έστω  $P(n)$  πιθανότητα επιτυχίας για γράφημα  $n$  κορυφών:
    - $P(n) = 1 - (1 - P(n)/4)^4$ , με λύση  $P(n) = \Omega(1/\log n)$
- Χρόνος εκτέλεσης συνολικά  $O(n^2 \log^3 n)$  για πιθανότητα επιτυχίας  $= 1 - O(1/n)$ .

# Monte Carlo vs Las Vegas

---

- Monte Carlo αλγόριθμοι (π.χ. min-cut):
  - Μπορεί να δώσουν **λάθος απάντηση** (με μικρή πιθανότητα), χρόνος εκτέλεσης **ντετερμινιστικός** (συνήθως!).
  - Πιθανότητα λάθους μπορεί να γίνει **πολύ-πολύ μικρή** με ανεξάρτητες επαναλήψεις.
  - Προβλήματα απόφασης: **one-sided error** και **two-sided error**.
  - Πολυωνυμικοί one-sided error αλγόριθμοι: **RP** και **coRP**.
  - Πολυωνυμικοί two-sided error αλγόριθμοι: **BPP**.
- Las Vegas αλγόριθμοι (π.χ. quicksort, quickselect):
  - **Πάντα σωστή απάντηση**, **χρόνος εκτέλεσης τυχαία μεταβλητή**.
  - Πολυωνυμικοί αλγόριθμοι: **ZPP**.

# Βασικές Έννοιες Πιθανότητας

---

- Δειγματοχώρος, γεγονός και πιθανότητα, τυχαία μεταβλητή.
  - $\Pr[A \cup B] = \Pr[A] + \Pr[B] - \Pr[A \cap B]$   
(γενικεύεται με μέθοδο εγκλεισμού – αποκλεισμού).
  - Union bound:  $\Pr[\cup_{i=1}^n A_i] \leq \sum_{i=1}^n \Pr[A_i]$
  - Πιθανότητα A υπό συνθήκη B:  $\Pr[A|B] = \Pr[A \cap B] / \Pr[B]$   
Γενίκευση:  $\Pr[\cap_{i=1}^n A_i] = \Pr[A_1] \Pr[A_2|A_1] \cdots \Pr[A_n | \cap_{i=1}^{n-1} A_i]$
  - Ανεξάρτητα γεγονότα:  $\Pr[A \cap B] = \Pr[A] \Pr[B]$ .
  - Αρνητικά σχετιζόμενα γεγονότα.



# Βασικές Έννοιες Πιθανότητας

- Μέση τιμή:  $\mathbb{E}[X] = \sum_{k=0}^{\infty} \Pr[X = k] k$ 
  - Ισοδύναμα (ακέραιες τυχαίες μεταβλ.):  $\mathbb{E}[X] = \sum_{k=1}^{\infty} \Pr[X \geq k]$
  - Γραμμικότητα:  $E[X+Y] = E[X] + E[Y]$ .
  - Ανισότητα Jensen: Αν  $f$  κυρτή συνάρτηση,  $E[f(X)] \geq f(E[X])$ .
  - Αν  $X$  και  $Y$  ανεξάρτητες:  $E[X Y] = E[X] E[Y]$ .
- Διακύμανση (variance):
  - $\text{Var}[X] = E[(X - E[X])^2] = E[X^2] - E[X]^2$
  - Τυπική απόκλιση (std deviation):  $\sigma_x = \text{Var}(X)^{1/2}$
  - Αν  $X$  και  $Y$  ανεξάρτητες:  $\text{Var}[X + Y] = \text{Var}[X] + \text{Var}[Y]$ .
- Probability generating function:
$$G_X(z) = \sum_{k=0}^{\infty} \Pr[X = k] z^k$$
$$\mathbb{E}[X] = G'(1)$$
$$\text{Var}[X] = G''(1) + G'(1) - G'(1)^2$$

# Παραδείγματα Κατανομών

---

- Bernoulli μεταβλητή  $X$ : 1 με **πιθ.  $p$** , και 0 διαφ.
  - $E[X] = p$ ,  $\text{Var}[X] = p(1 - p)$ ,  $G_X(z) = 1 - p + pz$ .
- Δυωνυμική κατανομή  $\text{Pr}[X = k] = \binom{n}{k} p^k (1 - p)^{n-k}$   
 $\text{Bin}(n, p)$ :
  - **Αριθμός επιτυχιών** σε  $n$  «ρίψεις» με πιθανότητα επιτυχίας  $p$ .
  - Άθροισμα  $n$  Bernoulli μεταβλητών με παράμετρο  $p$ .
  - $E[X] = np$ ,  $\text{Var}[X] = np(1 - p)$ ,  $G_X(z) = (1 - p + pz)^n$
- Γεωμετρική κατανομή  $\text{Geo}(p)$ :  $\text{Pr}[X = k] = (1 - p)^{k-1} p$ 
  - **Αριθμός «ρίψεων»** μέχρι την πρώτη **επιτυχία** (waiting time).
  - $E[X] = 1/p$ ,  $\text{Var}[X] = (1 - p)/p^2$ ,  $G_X(z) = pz / (1 - z + pz)$
  - Αμνησία:  $\text{Pr}[X = n+k \mid X > k] = \text{Pr}[X = n]$

# Μπάλες και Κουτιά

---

- Έχουμε  $m$  μπάλες και  $n$  κουτιά. Κάθε μπάλα επιλέγει το κουτί της ισοπίθανα και ανεξάρτητα.
  - Απλό μοντέλο, πλήθος εφαρμογών(!).
  - Μέγιστος #μπαλών σε κάποιο κουτί;
    - Load balancing. Hashing with chains.
  - Ελάχιστο  $m$  ώστε να εμφανιστεί κουτί με  $\geq 2$  μπάλες;
    - Birthday paradox.
  - Ελάχιστο  $m$  ώστε κανένα κουτί άδειο;
    - Coupon collecting.

# Μέγιστος # Μπαλών

□ Πιθανότητα να βρεθεί κουτί με  $\geq 3 \ln n / \ln \ln n$  μπάλες είναι  $\leq 1/n$ .

■  $L_i = \#$  μπαλών σε κουτί  $i$ :  $\Pr[L_i \geq k] \leq \binom{n}{k} \left(\frac{1}{n}\right)^k \quad k! \geq (k/e)^k$

$$\leq \frac{n^k e^k}{k^k n^k} = \left(\frac{e}{k}\right)^k$$

■ Συνεπώς  $\Pr \left[ L_i \geq \frac{3 \ln n}{\ln \ln n} \right] \leq n^{-2}$

■ ... και (από union bound)  $\Pr \left[ \exists i : L_i \geq \frac{3 \ln n}{\ln \ln n} \right] \leq \frac{n}{n^2} = \frac{1}{n}$

■ Πιο ακριβής ανάλυση είναι εφικτή [Gonnet].

□ Νδο με πιθανότητα  $\geq 1 - 1/n$ , υπάρχει κουτί με  $\Omega(\ln n / \ln \ln n)$  μπάλες.

# Δυο Μπάλες στο Ίδιο Κουτί

- Πιθανότητα όλες οι  $m$  ( $< n$ ) μπάλες σε διαφορετικό κουτί:

$$P_m = \frac{n}{n} \frac{n-1}{n} \frac{n-2}{n} \dots \frac{n-m+1}{n} = \prod_{k=1}^{m-1} \left(1 - \frac{k}{n}\right)$$
$$\leq \prod_{k=1}^{m-1} e^{-k/n} = e^{-m(m-1)/(2n)}$$

- Πιθανότητα τουλ. 2 μπάλες στο ίδιο κουτί  $\geq 1 - P_m$ 
  - Για  $n = 365$  και  $m = 28$ : πιθανότητα σε 28 ανθρώπους, κάποιος να έχουν γενέθλια την ίδια μέρα  $> 1 - e^{-1}$

# Συλλογή Κουπονιών

- Ελάχιστο  $m$  ώστε κανένα κουτί άδειο.
  - $Z_k = \#$  μπαλών όταν για πρώτη φορά  $\#$  γεμάτων κουτιών =  $k$ .
  - $X_k = Z_{k+1} - Z_k$ :  $\#$  μπαλών για να γεμίσει το  $k+1$  κουτί.
  - $X_k$  ακολουθεί **γεωμετρική κατανομή** με παράμετρο  $1 - k/n$ , και έχει  $E[X_k] = n/(n - k)$ .
  - Γραμμικότητα μέσης τιμής:  $E[Z_n] = \sum_{k=0}^{n-1} E[X_k] = \sum_{k=0}^{n-1} \frac{n}{n - k} = nH_n$
- Εμφανίζει **ισχυρή συγκέντρωση** γύρω από την μέση τιμή:
  - $Y_{j,k}$ : κουτί  $j$  είναι άδειο μετά τις πρώτες  $k$  μπάλες.  $\Pr[Y_{j,k}] = \left(1 - \frac{1}{n}\right)^k \leq e^{-k/n}$
  - Για κάθε  $\beta > 1$ , πιθανότητα κάποιο κουτί άδειο μετά από  $\beta n \ln n$  μπάλες:  $\leq n e^{-\beta \ln n / n} = n^{1-\beta}$
  - Μπορεί ν.δ.ο. για κάθε  $c$ , πιθανότητα κάποιο κουτί άδειο μετά από  $n(\ln n + c)$  μπάλες:  $\leq e^{-e^{-c}}$