



# Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών

---

## Προηγμένα Θέματα Αλγορίθμων

### Αλγόριθμοι Δικτύων και Πολυπλοκότητα

Εαρινό εξάμηνο 2023-2024

(ΕΜΠ – ΑΛΜΑ)

Διδάσκοντες: Α. Παγουρτζής – Δ. Φωτάκης – Θ. Λιανέας – Ο. Πλευράκης

---

## 1η Σειρά Ασκήσεων

Προθεσμία παράδοσης: 10/5/2024

**Άσκηση 1** (Min-Cut Algorithm, 1.5 μον.). Να λύσετε την [1, Άσκηση 1.24].

**Άσκηση 2** (Random Sampling, 1 μον.). Θεωρούμε μια δημοσκόπηση για τη στάση των πολιτών ως προς μια σημαντική πολιτικο-οικονομική μεταβολή. Οι πολίτες απαντούν στη δημοσκόπηση με “ναι” ή “όχι” (υπέρ ή εναντίον της μεταβολής). Αν το (πραγματικό) ποσοστό των πολιτών που τάσσονται υπέρ της μεταβολής είναι  $p$ , θέλουμε να υπολογίσουμε μια εκτίμηση  $\hat{p}$  του  $p$  ώστε  $\Pr[|\hat{p} - p| \leq \varepsilon p] > 1 - \delta$ , για δεδομένα  $\varepsilon, \delta \in (0, 1)$ . Για τη δημοσκόπηση, θα ρωτήσουμε  $N$  πολίτες, που επιλέγονται ισοπίθανα και ανεξάρτητα από το σύνολο των πολιτών. Η εκτίμησή μας  $\hat{p}$  θα είναι το ποσοστό των  $N$  πολιτών που τάσσονται υπέρ της μεταβολής. Χρησιμοποιώντας Chernoff-Hoeffding bounds, να υπολογίσετε (ως συνάρτηση των  $\varepsilon, \delta$ , και  $p$ ) το ελάχιστο μέγεθος  $N$  του δείγματος που χρειαζόμαστε. Βρείτε την τιμή του  $N$  για  $\varepsilon = 0.02$  και  $\delta = 0.05$ , αν γνωρίζουμε ότι  $p \in [0.1, 0.7]$  (και δείτε ότι αυτή η τιμή είναι ανεξάρτητη του πληθυσμού της χώρας!). Να υπολογίσετε ακόμη το ελάχιστο μέγεθος  $N'$  δείγματος (ως συνάρτηση των  $\varepsilon$  και  $\delta$ ) ώστε η εκτίμησή μας  $\hat{p}'$  να ικανοποιεί  $\Pr[|\hat{p}' - p| \leq \varepsilon] > 1 - \delta$ . Ποια είναι η τιμή του  $N'$  για  $\varepsilon = 0.02$  και  $\delta = 0.05$ ; Σημείωση: Πρόκειται για παραλλαγή της [1, Άσκησης 4.5].

**Άσκηση 3** (Sparsification, 2 μον.). (α) Έστω  $\mathbf{a}, \mathbf{x} \in [0, 1]^n$ , με  $\sum_i x_i = 1$  (θα λέμε ότι το  $\mathbf{x}$  είναι ένα διάνυσμα πιθανοτήτων στο  $[n] \equiv \{1, \dots, n\}$ ). Έστω ακόμη  $k(\varepsilon) = \lceil \ln(2)/(2\varepsilon^2) \rceil + 1$ . Να δείξετε ότι για κάθε  $\varepsilon > 0$ , υπάρχει ένα  $k(\varepsilon)$ -ομοιόμορφο διάνυσμα πιθανοτήτων  $\mathbf{y}$  στο  $[n]$  τέτοιο ώστε  $|\mathbf{a} \cdot \mathbf{x} - \mathbf{a} \cdot \mathbf{y}| \leq \varepsilon$ . Ένα διάνυσμα πιθανοτήτων  $\mathbf{y}$  είναι  $k$ -ομοιόμορφο ( $k$ -uniform) αν κάθε  $y_i$  είναι ακέραιο πολλαπλάσιο του  $1/k$ .

(β) Έστω  $A$  πίνακας  $m \times n$  με όλα τα στοιχεία του στο  $[0, 1]$  και έστω  $\mathbf{x}$  ένα διάνυσμα πιθανοτήτων στο  $[n]$ . Έστω ακόμη  $k(m, \varepsilon) = \lceil \ln(2m)/(2\varepsilon^2) \rceil + 1$ . Να δείξετε ότι για κάθε  $\varepsilon > 0$ , υπάρχει ένα  $k(m, \varepsilon)$ -ομοιόμορφο διάνυσμα πιθανοτήτων  $\mathbf{y}$  στο  $[n]$  τέτοιο ώστε  $\|A\mathbf{x} - A\mathbf{y}\|_\infty \leq \varepsilon$ .

Υπόδειξη: Να χρησιμοποιήσετε το ακόλουθο Hoeffding bound: Έστω  $X_1, \dots, X_n$  ανεξάρτητες τυχαίες μεταβλητές στο  $[0, 1]$ , και έστω  $X = (\sum_{i=1}^n X_i) / n$ . Για κάθε  $\varepsilon > 0$ ,  $\Pr[|X - \mathbb{E}X| > \varepsilon] \leq 2e^{-2n\varepsilon^2}$ .

**Άσκηση 4** (Capacited Max  $k$ -Cut, 1.5 μον.). Στο Max  $k$ -Cut πρόβλημα δίνεται απλό μη κατευθυνόμενο γράφημα  $G(V, E, w)$ , με θετικά ακέραια βάρη  $w : E \rightarrow \mathbb{N}^*$  στις ακμές, και ζητείται μια διαμέριση των κορυφών σε  $k \geq 2$  σύνολα  $(S_1, \dots, S_k)$ , με  $\bigcup_{i=1}^k S_i = V$ , ώστε να μεγιστοποιηθεί το συνολικό βάρος των ακμών με άκρα σε διαφορετικά σύνολα. Ειδικότερα, αν συμβολίσουμε με

$$\delta(S_1, \dots, S_k) = \left\{ e = \{u, v\} \in E : v \in S_i, u \in S_j \text{ και } i \neq j \right\}$$

το σύνολο των ακμών στο  $k$ -cut  $(S_1, \dots, S_k)$ , ζητείται να μεγιστοποιήσουμε το

$$w(S_1, \dots, S_k) = \sum_{e \in \delta(S_1, \dots, S_k)} w(e).$$

Θεωρούμε παραλλαγή του προβλήματος Max  $k$ -Cut όπου τα επιθυμητά μεγέθη  $(c_1, \dots, c_k)$ , με  $c_1 + \dots + c_k = |V|$  των συνόλων που ορίζουν το  $k$ -cut είναι δεδομένα. Εφαρμόζουμε τον πιθανοτικό αλγόριθμο που τοποθετεί κάθε κορυφή  $v$  στο σύνολο  $S_i$  τυχαία, με πιθανότητα  $c_i/|V|$ , και ανεξάρτητα. Να υπολογίσετε την αναμενόμενη τιμή του  $w(S_1, \dots, S_k)$  (και να διερευνήσετε πότε μεγιστοποιείται). Να υπολογίσετε ακόμη άνω και κάτω φράγματα (ώστε να ισχύουν με μεγάλη πιθανότητα) για τα μεγέθη των συνόλων που προκύπτουν.

**Άσκηση 5** (1 μον.). Θεωρούμε τον Αλγόριθμο Υποδιπλασιασμού (Halving Algorithm, όπως παρουσιάζεται στις διαφάνειες τις αντίστοιχης διάλεξης), που επιδιώκει να ελαχιστοποιήσει το πλήθος των

λαθών σε περιβάλλον online learning. Εξετάζουμε την περίπτωση που η κλάση υποθέσεων  $\mathcal{H}$  είναι πεπερασμένη και τα δείγματα κατηγοριοποιούνται με βάση υπόθεση  $f \in \mathcal{H}$  (realizability).

Να δείξετε ότι αν τα δείγματα  $(x_t, f(x_t))$  έρχονται από μια οποιαδήποτε (άγνωστη, αλλά συγκεκριμένη) κατανομή  $\mathcal{D}$  και το σύνολο έγκυρων υποθέσεων  $S_t$  δεν μεταβάλλεται για  $\Omega(\log(1/\delta)/\varepsilon)$  συνεχόμενα δείγματα, τότε με πιθανότητα τουλάχιστον  $1 - \delta$ , κάθε έγκυρη υπόθεση  $h \in S_t$  επιτυγχάνει loss  $L_{(\mathcal{D}, f)}(h) \leq \varepsilon$  (δηλαδή έχουμε επιτύχει την εγγύηση του PAC Learning). Ποια είναι η δειγματική πολυπλοκότητα του αλγορίθμου για πεπερασμένη κλάση υποθέσεων  $\mathcal{H}$ ;

**Άσκηση 6** (1 μον.). Να επαναλάβετε την ανάλυση του Weighted Majority Algorithm (WMA, όπως παρουσιάζεται στις διαφάνειες της αντίστοιχης διάλεξης) για την περίπτωση που το βάρος εμπιστοσύνης κάθε ειδικού / υπόθεσης  $h \in \mathcal{H}$  πολλαπλασιάζεται με  $(1 - \varepsilon)$  (αντί για  $1/2$ ) κάθε φορά που ο ειδικός  $h$  κάνει λάθος (έχουμε δηλαδή ότι για κάθε  $h$  με  $h(x_t) \neq y_t$ ,  $w_{t+1}(h) = (1 - \varepsilon)w_t(h)$ ).

**Άσκηση 7** (Ανάλυση Regret του Αλγόριθμου Hedge, 2 μον.). Θεωρούμε τον παρακάτω αλγόριθμο για online learning / online linear optimization και αναλύουμε το regret που επιτυγχάνει.

- **Input:**  $n$  actions  $\{1, \dots, n\}$ , time horizon  $T$ ,  $\mathbf{w}_1 = (1, \dots, 1)$ ,  $\mathbf{x}_1 = (1/n, \dots, 1/n)$
- for  $t = 1$  to  $T$  do:
  - Select action  $i_t \in \{1, \dots, n\}$  with probability  $\mathbf{x}_t(i_t)$
  - Get loss  $\ell_t \in [0, 1]^n$  for all actions and incur loss  $\ell_t(i_t)$
  - Update weights  $\mathbf{w}_{t+1}(i) = \mathbf{w}_t(i)e^{-\eta\ell_t(i)}$ , for all  $i \in \{1, \dots, n\}$
  - Update probabilities  $\mathbf{x}_{t+1}(i) = \frac{\mathbf{w}_{t+1}(i)}{\sum_{i=1}^n \mathbf{w}_{t+1}(i)}$ , for all  $i \in \{1, \dots, n\}$

(α) Θεωρούμε τη συνάρτηση δυναμικού  $\Phi(t) = \sum_{i=1}^n w_t(i)$  (συνολικό βάρος εμπιστοσύνης των actions τη χρονική στιγμή  $t$ ). Αρχικά είναι  $\Phi(1) = n$ . Να δείξετε ότι  $\Phi(T) \geq e^{-\eta \sum_{t=1}^T \ell_t(i^*)}$ , όπου  $i^* = \arg \min_i \sum_{t=1}^T \ell_t(i)$  η βέλτιστη επιλογή.

(β) Να δείξετε ακόμη ότι για κάθε  $t \geq 1$ ,

$$\Phi(t+1) \leq \Phi(t)e^{-\eta \mathbf{x}_t \cdot \ell_t + \eta^2 \mathbf{x}_t \ell_t^2},$$

όπου  $\ell_t^2(i) = (\ell_t(i))^2$ , για όλα τα  $i \in \{1, \dots, n\}$ . Χρησιμοποιώντας αυτή τη σχέση, να βρείτε ένα άνω φράγμα για το  $\Phi(T)$  ως συνάρτηση του  $\Phi(1) = n$ .

(γ) Χρησιμοποιώντας τα άνω και κάτω φράγματα για την  $\Phi(T)$  που υπολογίσατε στα (α) και (β) και το γεγονός ότι  $\ell_t \in [0, 1]^n$ , για κάθε  $t \in \{1, \dots, T\}$ , να δείξετε ότι:

$$\text{Regret}(T) = \sum_{t=1}^T \ell_t(i_t) - \sum_{t=1}^T \ell_t(i^*) \leq \eta T + \ln(n)/\eta$$

Ποια τιμή του  $\eta$  θα επιλέγατε; Ποιο είναι το  $\text{Regret}(T)$  που επιτυγχάνει ο αλγόριθμος για αυτή την τιμή του  $\eta$ ;

## Αναφορές

- [1] M. Mitzenmacher and E. Upfal. *Probability and Computing: Randomized Algorithms and Probabilistic Analysis*. Cambridge University Press, 2005.