

## הרצאה 7: יציבות + אדפטיביות בסטרימינג

Source: Lecture notes by  
Aaron Roth and Adam Smith

מרצה: אורי שטמר

**אבחנה 1:** יהי  $\mathcal{A}$  אלגוריתם  $(\epsilon, \delta)$ -DP-יציב אשר פועל על דטהבייס בגודל  $n$ . יהי  $\mathcal{B}$  אלגוריתם אשר פועל על  $T$  דטהבייסים בגודל  $n$  כ"א, מריץ על כל אחד מהם את אלגוריתם  $\mathcal{A}$  ומחזיר את  $T$  הפלטים שהוא מקבל. אזי  $\mathcal{B}$  מקיים  $(\epsilon, \delta)$ -DP-יציבות.

**הוכחה:** תרגיל

**משפט 2:** יהי  $W$  מכניזם  $(\epsilon, \delta)$ -DP-יציב אשר מקבל כקלט מדגם  $S$  בגודל  $n = \Omega\left(\frac{1}{\epsilon^2} \log \frac{1}{\delta}\right)$  ופולט שאילתא סטטיסטית  $q$ . אזי, לכל התפלגות  $\mathcal{D}$  מתקיים

$$\Pr_{\substack{S \sim \mathcal{D}^n \\ q \leftarrow W(S)}} \left[ |q(S) - q(\mathcal{D})| > 10\epsilon \right] < \frac{\delta}{\epsilon}$$

**"הוכחה" של משפט 2 עם הרבה פרטים חסרים:**

התנאים של משפט 2 הם:

- $W$  הוא מכניזם  $(\epsilon, \delta)$ -DP-יציב אשר מקבל כקלט מדגם  $S$  ופולט שאילתא סטטיסטית  $q$
- $S$  הוא מדגם המכיל  $n$  דגימות iid מהתפלגות כלשהי  $\mathcal{D}$
- אנחנו מסמנים  $q \leftarrow W(S)$

מטרה: להראות שבהסתברות גבוהה מתקיים  $q(S) \approx q(\mathcal{D})$

התוכנית: נתחיל מלהראות חסם בתוחלת ואז נחזק אותו קצת ואח"כ נהפוך אותו לחסם בהסתברות גבוהה.

**טענה א:**

$$\mathbb{E}_{\substack{S \sim \mathcal{D}^n \\ q \leftarrow W(S)}} [q(S)] \approx \mathbb{E}_{\substack{S \sim \mathcal{D}^n \\ q \leftarrow W(S)}} [q(\mathcal{D})]$$

**הסבר:** נסתכל על 2 הניסויים הבאים:

$$\begin{array}{l} S = (x_1, \dots, x_n) \sim \mathcal{D}^n \\ z \sim \mathcal{D} \\ i \in_R \{1, 2, \dots, n\} \\ q \leftarrow W(S) \\ \text{Return } q(x_i) \end{array}$$

$\approx$   
(בגלל DP-יציבות)

$$\begin{array}{l} S = (x_1, \dots, x_n) \sim \mathcal{D}^n \\ z \sim \mathcal{D} \\ i \in_R \{1, 2, \dots, n\} \\ q \leftarrow W(S \setminus \{x_i\} \cup \{z\}) \\ \text{Return } q(x_i) \end{array}$$

כאן הפלט הוא הפעלה של  $q$  על איבר אקראי מהמדגם  $S$ . לכן בתוחלת על פני  $i$  מה שמוחזר כאן זה הממוצע האמפירי, כלומר  $q(S)$

כאן הפלט הוא  $q$  מופעלת על איבר אקראי מההתפלגות  $\mathcal{D}$  (בלתי תלוי ב- $q$ ). לכן בתוחלת על פני  $x_i$  מה שמוחזר כאן זה  $q(\mathcal{D})$

**טענה ב:** יהי  $B$  אלגוריתם הפועל על  $T$  מדגמים  $\vec{S} = (S_1, \dots, S_T) \in (X^n)^T$  ומחזיר שאילתא  $q: X \rightarrow \{0,1\}$  וגם מספר  $1 \leq t \leq T$ . אם  $B$  הוא  $\text{DP-}\epsilon, \delta$ -יציב אזי

$$\mathbb{E}_{\vec{S} \sim \mathcal{D}^n} [q(S_t)] \approx \mathbb{E}_{\vec{S} \sim \mathcal{D}^n} [q(\mathcal{D})]$$

ההוכחה של טענה ב דומה להוכחה של טענה א (אבל צריך לעקוב אחרי כל  $T$  המדגמים...)

**טענה ג (=משפט 2):** יהי  $W$  אלגוריתם  $\text{DP-}\epsilon, \delta$ -יציב הפולט שאילתא  $q: X \rightarrow \{0,1\}$ . יהי  $S \sim \mathcal{D}^n$  ונסמן  $q \leftarrow W(S)$ . אזי בהסתברות גבוהה מתקיים  $q(S) \approx q(\mathcal{D})$

**הסבר:** נניח בשלילה שבהסתברות מסוימת  $\beta$  מתקיים שאלגוריתם  $W(S)$  פולט  $q$  כך ש-  $|q(S) - q(\mathcal{D})|$  גדול. נשתמש ב-  $W$  כדי לבנות אלגוריתם יציב  $B$  שסותר את טענה ב:

אלגוריתם  $B$ : קלט  $S_1, \dots, S_T$  כאשר כל  $S_t \sim \mathcal{D}^n$ , עבור  $T \approx \frac{1}{\beta}$ . לכל  $1 \leq t \leq T$  הרץ  $q_t \leftarrow W(S_t)$  (1)

\* לפי ההנחה בשלילה על  $W$  ולפי בחירת  $T$ , בהסתברות גבוהה קיים אינדקס  $t$  כך ש-  $|q_t(S_t) - q_t(\mathcal{D})|$  גדול.

(2) בחר  $t$  כנ"ל בעזרת אלגוריתם NoisyAgrmax והחזר  $(q_t, t)$ .

\* בהסתברות גבוהה נקבל ש-  $|q_t(S_t) - q_t(\mathcal{D})|$  הוא גדול וזה יסתור את החסם בתוחלת של טענה ב.


אפשר להראות שאלגוריתם  $B$  הוא  $\text{DP-}\epsilon, \delta$ -יציב (עם בערך אותם פרמטרים כמו  $W$ ) ואפשר להראות שבהסתברות גבוהה (וגם בתוחלת) הערך האמפירי של השאילתא שהוא מחזיר רחוק מאוד מהערך שלה על פני ההתפלגות. זה סותר את טענה ב ולכן מפריך את ההנחה בשלילה שקיים  $W$  כזה.

## Adaptive Streaming

### הגדרה 1 (מודל הסטרימינג הלא-אדפטיבי):

- A stream of length  $m$  over domain  $[n]$  is a sequence of updates  $((u_1, \Delta_1), \dots, (u_m, \Delta_m))$
- Here  $u_i \in [n]$  is the  $i$ th item and  $\Delta_i \in \mathbb{Z}$  is its weight
- Let  $g: ([n] \times \mathbb{Z})^* \rightarrow \mathbb{R}$  be a function
- At time  $i$  we obtain  $(u_i, \Delta_i)$  and need to output  $z_i \in (1 \pm \alpha) \cdot g((u_1, \Delta_1), \dots, (u_i, \Delta_i))$
- **Requirement: Sublinear space (we assume  $n \gg m$ )**

**דוגמה פשוטה:** נניח שהפונקציה  $g$  סופרת את מספר האיברים השונים ב stream. אזי,



(כאן האיברים ב stream מגיעים משמאל לימין)

**דוגמה יותר רצינית:**

- Every item in the stream is a pair  $(\mathbf{u}_i, \Delta_i)$  where  $\mathbf{u}_i \in \mathbb{R}^n$  is a standard basis vector and  $\Delta_i \in \mathbb{R}$  is its weight
- At every time step  $i$ , the goal is to estimate  $\|f^{(i)}\|_2^2$  for  $f^{(i)} = \Delta_1 \cdot \mathbf{u}_1 + \dots + \Delta_i \cdot \mathbf{u}_i$

**האלגוריתם:**

1. Let  $A$  be  $t \times n$  matrix with entries uniformly in  $\{\pm 1\}$
2. Initiate  $\mathbf{y} = \vec{0} \in \mathbb{R}^t$
3. For  $i = 1, 2, \dots, m$  do:
  - Obtain the next update vector  $\mathbf{v}_i = \Delta_i \cdot \mathbf{u}_i$
  - Let  $\mathbf{y} \leftarrow \mathbf{y} + A \cdot \mathbf{v}_i$
  - Output estimation  $z_i = \frac{1}{t} \cdot \|\mathbf{y}\|_2^2$

**הניתוח:**

נסמן ב-  $a_\ell$  את השורה ה- $\ell$  במטריצה  $A$ .

נשים לב שמתקיים:

$$z_i = \frac{1}{t} \cdot \|A \cdot \mathbf{v}_1 + \dots + A \cdot \mathbf{v}_i\|_2^2 = \frac{1}{t} \cdot \|A \cdot f^{(i)}\|_2^2 = \frac{(a_1 \cdot f^{(i)})^2 + \dots + (a_t \cdot f^{(i)})^2}{t}$$

כעת, לכל קביעה של  $f \in \mathbb{R}^n$  ולכל  $\ell \in [t]$  מתקיים

$$\mathbb{E}[a_\ell \cdot f] = \mathbb{E} \left[ \sum_{j \in [n]} a_{\ell,j} \cdot f_j \right] = \sum_{j \in [n]} \mathbb{E}[a_{\ell,j}] \cdot f_j = 0$$

ובנוסף,

$$\mathbb{E}[(a_\ell \cdot f)^2] = \mathbb{E} \left[ \left( \sum_{j \in [n]} a_{\ell,j} \cdot f_j \right)^2 \right] \stackrel{\text{(pairwise)}}{=} \sum_{j \in [n]} \mathbb{E}[(a_{\ell,j} \cdot f_j)^2] = \sum_{j \in [n]} \mathbb{E}[a_{\ell,j}^2] \cdot f_j^2 = \sum_{j \in [n]} f_j^2 = \|f\|_2^2$$

כאשר המעבר המסומן באדום נכון כי עבור זוגות  $j \neq j'$  נקבל שמתקיים  $\mathbb{E}[a_{\ell,j} \cdot a_{\ell,j'}] = \mathbb{E}[a_{\ell,j}] \cdot \mathbb{E}[a_{\ell,j'}] = 0$  בגלל אי-תלות.

כלומר אנחנו רואים שבתוחלת,  $(a_\ell \cdot f)^2$  נותן לנו בדיוק את מה שאנחנו רוצים. אבל מהי השונות? נזכור שלפי הגדרה:

$$\text{Var}[(a_\ell \cdot f)^2] = \mathbb{E}[(a_\ell \cdot f)^4] - (\mathbb{E}[(a_\ell \cdot f)^2])^2$$

אז נחשב כ"א משני הביטויים האלה:

$$\mathbb{E}[(a_\ell \cdot f)^4] = \mathbb{E} \left[ \left( \sum_{j \in [n]} a_{\ell,j} \cdot f_j \right)^4 \right] \stackrel{\text{(4wise)}}{=} \sum_{j \in [n]} f_j^4 + 6 \sum_{j \neq j'} f_j^2 \cdot f_{j'}^2$$

$$(\mathbb{E}[(a_\ell \cdot f)^2])^2 = \left( \sum_{j \in [n]} f_j^2 \right)^2 = \sum_{j \in [n]} f_j^4 + 2 \sum_{j \neq j'} f_j^2 \cdot f_{j'}^2$$

ולכן אנחנו מקבלים שמתקיים

$$\text{Var}[(a_\ell \cdot f)^2] = 4 \sum_{j \neq j'} f_j^2 \cdot f_{j'}^2 \leq 2 \left( \sum_{j \in [n]} f_j^2 \right)^2 = 2 \cdot \|f\|_2^4$$

וזה רק עבור שורה אחת. האלגוריתם שלנו מחזיר את המיצוע על פני  $t$  השורות. המיצוע הזה לא משנה את העובדה שבתוחלת אנחנו מחזירים את הדבר הנכון, אבל את השונות זה מקטין בצורה משמעותית. נניח שהשורות במטריצה הן בלתי תלויות. אזי:

$$\text{Var} \left[ \frac{\sum_{\ell=1}^t (a_\ell \cdot f)^2}{t} \right] = \frac{1}{t^2} \cdot \text{Var} \left[ \sum_{\ell=1}^t (a_\ell \cdot f)^2 \right] \stackrel{\text{independent rows}}{=} \frac{1}{t^2} \cdot \sum_{\ell=1}^t \text{Var}[(a_\ell \cdot f)^2] \leq \frac{2 \cdot \|f\|_2^4}{t}$$

לכן, לפי אי-שוויון צ'בישב, לכל  $\alpha > 0$  מתקיים:

$$\Pr \left[ \left| \frac{\sum_{\ell=1}^t (a_\ell \cdot f)^2}{t} - \|f\|_2^2 \right| > \alpha \cdot \|f\|_2^2 \right] \leq \frac{\text{Var} \left[ \frac{\sum_{\ell=1}^t (a_\ell \cdot f)^2}{t} \right]}{\alpha^2 \cdot \|f\|_2^4} \leq \frac{2}{t \cdot \alpha^2}$$

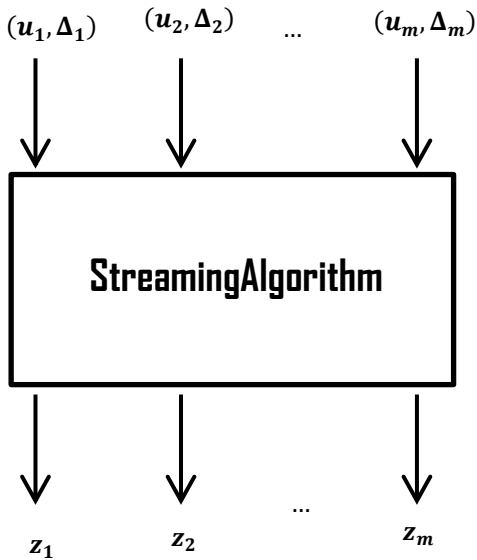
נבחר  $t = \frac{2}{\alpha^2 \beta}$  ונקבל

$$\Pr \left[ \left| \frac{\sum_{\ell=1}^t (a_\ell \cdot f)^2}{t} - \|f\|_2^2 \right| > \alpha \cdot \|f\|_2^2 \right] \leq \beta$$


כלומר, כל אחת מהתשובות שהאלגוריתם מחזיר מדוייקת עד כדי טעות כפלית של  $(1 \pm \alpha)$  בהסתברות לפחות  $1 - \beta$ .

שימו לב: בשביל הניתוח היינו צריכים להניח שהווקטור  $f$  נקבע מראש. באופן כללי, במודל ה *streaming* הלא-אדפטיבי אנחנו מניחים שכל ה *stream* נקבע מראש (אבל האלגוריתם מקבל את האיברים אחד אחד).  
 בצורה:

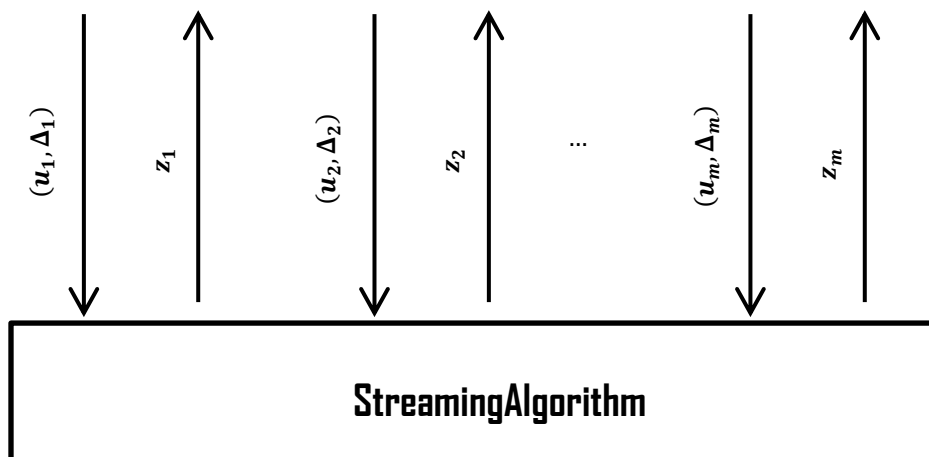
$$(u_1, \Delta_1), \dots, (u_m, \Delta_m) = \text{fixed stream (unknown to the algorithm)}$$



במודל האדפטיבי לעומת זאת, האיברים ב *stream* לא נקבעים מראש. הם נקבעים תוך כדי ריצה על ידי "יריב" שרואה את התשובות שהאלגוריתם החזיר עד עכשיו. בצורה:



Adversary chooses  $(u_i, \Delta_i)$  based on all previous items and answers



מה הקושי עכשיו? האיברים ב stream נבחרים על סמך התשובות הקודמות של האלגוריתם ולכן יכולות להיות תלויות באקראיות הפנימית של האלגוריתם. התלויות האלה משבשות את ההבטחות של רוב אלגוריתמי ה streaming הקיימים.

### הגדרה (מודל ה streaming האדפטיבי):

- Fix a function  $g: ([n] \times \mathbb{Z})^* \rightarrow \mathbb{R}$
- Two-player game between a (randomized) **StreamingAlgorithm** and an **Adversary**
- In the  $i$ th round:
  1. The **Adversary** chooses an update  $(u_i, \Delta_i)$  for the stream, which can depend on all previous stream updates and outputs of **StreamingAlgorithm**
  2. The **StreamingAlgorithm** processes the new update and outputs its current response  $z_i$
- The goal of the **Adversary** is to make the **StreamingAlgorithm** output an incorrect response  $z_i$  at some point  $i$

### Adversary for the AMS Sketch

#### Recall AMS sketch

- Random matrix  $A \in \{\pm 1\}^{t \times n}$
- After the  $i$ th update, respond with  $\frac{1}{t} \|A \cdot f^{(i)}\|_2^2 = \left\| \frac{1}{\sqrt{t}} A \cdot f^{(i)} \right\|_2^2$  where  $f^{(i)} = \Delta_1 \cdot u_1 + \dots + \Delta_i \cdot u_i$

#### The attack

- Set  $w \leftarrow C \cdot \sqrt{t} \cdot e_1$
- For  $i = 2, 3, \dots, m = O(t)$  do
  1. **old**  $\leftarrow \left\| \frac{1}{\sqrt{t}} A \cdot w \right\|_2^2$
  2.  $w \leftarrow w + e_i$
  3. **new**  $\leftarrow \left\| \frac{1}{\sqrt{t}} A \cdot w \right\|_2^2$
  4. If **new**  $>$  **old** then  $w \leftarrow w - e_i$

#### Analysis

- At all times  $\|w\|_2^2 \geq C^2 \cdot t$  by init  
 $\Rightarrow$  Suffices to show that  $\left\| \frac{1}{\sqrt{t}} A \cdot w \right\|_2^2$  drops below  $C^2/2 \cdot t$
- $\text{new}_i = \left\| \frac{1}{\sqrt{t}} A \cdot (w + e_i) \right\|_2^2 = \left\| \frac{1}{\sqrt{t}} A \cdot w \right\|_2^2 + \left\| \frac{1}{\sqrt{t}} A \cdot e_i \right\|_2^2 + 2 \left\langle \frac{1}{\sqrt{t}} A w, \frac{1}{\sqrt{t}} A e_i \right\rangle$   
 $= \text{old}_i + 1 + 2 \left\langle \frac{1}{\sqrt{t}} A w, \frac{1}{\sqrt{t}} A e_i \right\rangle$
- So,  $\text{new}_i - \text{old}_i \approx 2 \left\langle \frac{1}{\sqrt{t}} A w, \frac{1}{\sqrt{t}} A e_i \right\rangle$

This inner product is symmetric, and is “negative enough” with constant probability, because  $A e_i$  is the  $i^{\text{th}}$  column of  $A$  which is uniform on  $\{\pm 1\}$  even conditioned on  $A w$  (which is independent of the  $i^{\text{th}}$  column of  $A$ ).