

הרצאה 6: יציבות

Source: Lecture notes by
Aaron Roth and Adam Smith

מרצה: אורי שטמר

נניח שיש לנו k מכניזמים M_1, M_2, \dots, M_k שכל אחד מהם הוא (ϵ, δ) -DP-יציב (כל אחד מהם מקבל דטהבייס + פרמטר). נחשוב על המכניזם \vec{M} אשר מקבל מבצע קומפוזיציה אדפטיבית של כל המכניזמים האלה. כלומר:

$$\vec{M}(S) = M_k \left(S, M_{k-1} \left(S, M_{k-2} \left(S, M_{k-3} (S, \dots) \right) \right) \right)$$

משפט 1: יהיו $0 < \epsilon, \delta \leq 1$. יהי \vec{M} מכניזם המבצע k הפעלות אדפטיביות של מכניזמים שכל אחד הוא (ϵ, δ) -DP-יציב (ללא גישה נוספת לדטהבייס). אזי \vec{M} הוא

$$\text{DP-יציב} \left(2k \cdot \epsilon^2 + \sqrt{2k \ln \left(\frac{1}{k\delta} \right)} \cdot \epsilon, 2k\delta \right)$$

לשם פשטות, אנחנו נוכיח רק את הגרסה מוחלשת הבאה של משפט הקומפיזיציה

משפט 2: יהיו $0 < \epsilon, \delta \leq 1$. יהי \vec{M} מכניזם המבצע k הפעלות אדפטיביות של מכניזמים שכל אחד הוא $(\epsilon, 0)$ -DP-יציב (ללא גישה נוספת לדטהבייס). אזי לכל $\hat{\delta} > 0$ המכניזם \vec{M} הוא $(\hat{\epsilon}, \hat{\delta})$ -DP-יציב עבור

$$\hat{\epsilon} = 2k\epsilon^2 + \sqrt{2k \cdot \ln(1/\hat{\delta})} \epsilon$$

הוכחה:

נקבע זוג מדגמים שכנים S, S' . עלינו להראות כי לכל מאורע B מתקיים

$$\Pr[\vec{M}(S) \in B] \leq e^{\hat{\epsilon}} \cdot \Pr[M(S') \in B] + \hat{\delta}$$

נסמן:

$Y_1, \dots, Y_k =$ משתנים מקריים המיצגים את הפלטים של M_1, \dots, M_k במהלך הריצה של $\vec{M}(S)$.

$Y'_1, \dots, Y'_k =$ משתנים מקריים המיצגים את הפלטים של M_1, \dots, M_k במהלך הריצה של $\vec{M}(S')$.

בנוסף נסמן

$$V = (Y_1, \dots, Y_k), \quad V' = (Y'_1, \dots, Y'_k)$$

בסימונים האלה, מספיק להוכיח שלכל מאורע B מתקיים

$$\Pr[V \in B] \leq e^{\hat{\epsilon}} \cdot \Pr[V' \in B] + \hat{\delta}$$

טענת עזר 3: מספיק להוכיח כי

$$\Pr_{v \leftarrow V} \left[\ln \left(\frac{\Pr[V = v]}{\Pr[V' = v]} \right) > \hat{\epsilon} \right] < \hat{\delta}$$

$$W = \left\{ v \in \text{Supp}(V) : \ln \left(\frac{\Pr[V = v]}{\Pr[V' = v]} \right) > \varepsilon \right\}$$

לפי התנאים של טענת העזר, מתקיים

$$\Pr[V \in W] < \delta$$

נקבע קבוצה B . כעת,

$$\Pr[V \in B] = \Pr[V \in B \cap W] + \Pr[V \in B \setminus W] \leq \delta + e^\varepsilon \cdot \Pr[V' \in B \setminus W] \leq \delta + e^\varepsilon \cdot \Pr[V' \in B]$$

מ.ש.ל. (טענת העזר)

נחזור להוכחת המשפט.

נקבע סדרה $v = (y_1, y_2, \dots, y_k)$ של פלטים עבור M_1, \dots, M_k ונחשב

$$\begin{aligned} \ln \left(\frac{\Pr[V = v]}{\Pr[V' = v]} \right) &= \ln \left(\prod_{i=1}^k \frac{\Pr[Y_i = y_i | Y_1 = y_1, Y_2 = y_2, \dots, Y_{i-1} = y_{i-1}]}{\Pr[Y'_i = y_i | Y'_1 = y_1, Y'_2 = y_2, \dots, Y'_{i-1} = y_{i-1}]} \right) \\ &= \sum_{i=1}^k \ln \left(\frac{\Pr[Y_i = y_i | Y_1 = y_1, Y_2 = y_2, \dots, Y_{i-1} = y_{i-1}]}{\Pr[Y'_i = y_i | Y'_1 = y_1, Y'_2 = y_2, \dots, Y'_{i-1} = y_{i-1}]} \right) \\ &\triangleq \sum_{i=1}^k c_i(y_1, \dots, y_{i-1}, y_i) \end{aligned}$$

אז הצגנו את $\ln \left(\frac{\Pr[V=v]}{\Pr[V'=v]} \right)$ כסכום של k משתנים מקריים C_1, C_2, \dots, C_k כאשר כל C_i כזה הוא משתנה מקרי המקבל את הערך $c_i(y_1, \dots, y_{i-1}, y_i)$.

עכשיו אנחנו רוצים להפעיל את אי-שוויון אזומה על המשתנים המקריים האלה.

הערה: האקראיות היא מעל הגרלת $V = (Y_1, \dots, Y_k)$, כלומר אנחנו רוצים לחסום את

$$\Pr_{v \leftarrow V} \left[\ln \left(\frac{\Pr[V = v]}{\Pr[V' = v]} \right) > \varepsilon \right] = \Pr_{v \leftarrow V} \left[\sum_{i=1}^k c_i(y_1, \dots, y_{i-1}, y_i) > \varepsilon \right]$$

כדי להפעיל את אזומה אנחנו צריכים לחסום אם $|C_i|$ ואנחנו צריכים לנתח תוחלת. נזכור כי לפי הגדרה,

$$c_i(y_1, y_2, \dots, y_i) = \ln \left(\frac{\Pr[Y_i = y_i | Y_1 = y_1, Y_2 = y_2, \dots, Y_{i-1} = y_{i-1}]}{\Pr[Y'_i = y_i | Y'_1 = y_1, Y'_2 = y_2, \dots, Y'_{i-1} = y_{i-1}]} \right) = ((1))$$

כאשר Y_j, Y'_j הם משתנים מקריים המייצגים את התשובה ה- j במהלך הריצה על S, S' בהתאמה.

נזכור כי ברגע שקבענו את התשובות y_1, y_2, \dots, y_{i-1} אז זה קובע את הפרמטר $p_i = p_i(y_1, y_2, \dots, y_{i-1})$ שמזוין להפעלה של המכניזם M_i .

לכן,

$$((1)) = \ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) = ((2))$$

נעת נזכור שהמכניזם M_i הוא DP -יציב ולכן, לפי הגדרת DP -יציבות מתקיים

$$((2)) \in [-\varepsilon, \varepsilon]$$

בפרט, קיבלנו כי לכל y_1, y_2, \dots, y_i מתקיים

$$|c_i(y_1, y_2, \dots, y_i)| \leq \varepsilon$$

ולכן

$$\Pr[|C_i| \leq \varepsilon] = 1$$

נעת נחשב את התוחלת המותנית:

$$\mathbb{E} \left[C_i \mid C_1 = c_1, \dots, C_{i-1} = c_{i-1} \right] = \mathbb{E}_{v \leftarrow V} \left[c_i(y_1, y_2, \dots, y_i) \mid C_1 = c_1, \dots, C_{i-1} = c_{i-1} \right]$$

$$\underbrace{=}_{\substack{\text{לפי החשבון שעשינו} \\ \text{במשוואות (1), (2)}}} \mathbb{E}_{v \leftarrow V} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \mid C_1 = c_1, \dots, C_{i-1} = c_{i-1} \right]$$

$$\underbrace{=}_{\substack{\text{משפט} \\ \text{התוחלת} \\ \text{השלמה}}} \sum_{y_1, \dots, y_{i-1}} \mathbb{E}_{v \leftarrow V} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \mid y_1, \dots, y_{i-1} \right] \cdot \Pr_{v \leftarrow V} \left[y_1, \dots, y_{i-1} \mid c_1, \dots, c_{i-1} \right]$$

$$= \sum_{y_1, \dots, y_{i-1}} \mathbb{E}_{y_i \leftarrow Y_i} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \mid y_1, \dots, y_{i-1} \right] \cdot \Pr_{v \leftarrow V} \left[y_1, \dots, y_{i-1} \mid c_1, \dots, c_{i-1} \right] = ((3))$$

כמו שאמרנו קודם, ברגע שקבענו את y_1, \dots, y_{i-1} אז זה קובע את הפרמטר $p_i = p_i(y_1, y_2, \dots, y_{i-1})$ וקובע את ההתפלגות של Y_i להיות הפלט של $M_i(S, p_i)$. לכן,

$$((3)) = \sum_{y_1, \dots, y_{i-1}} \mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] \cdot \Pr_{v \leftarrow V} \left[y_1, \dots, y_{i-1} \mid c_1, \dots, c_{i-1} \right] = ((4))$$

טענת עזר 4 (נוכח עוד רגע): לכל קביעה של p_i מתקיים

$$\mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] \leq 2 \cdot \varepsilon^2$$

בעזרת טענת עזר 4 נקבל

$$((4)) \leq \sum_{y_1, \dots, y_{i-1}} 2 \cdot \varepsilon^2 \cdot \Pr_{v \leftarrow V} [y_1, \dots, y_{i-1} \mid c_1, \dots, c_{i-1}] = 2 \cdot \varepsilon^2$$

איפה אנחנו בהוכחה של משפט 2?

אנחנו רוצים להוכיח ש-

$$\Pr_{v \leftarrow V} \left[\sum_{i=1}^k c_i(y_1, \dots, y_{i-1}, y_i) > \hat{\varepsilon} \right] \leq \delta$$

והראינו כי לכל i מתקיים $|C_i| \leq \varepsilon$ וגם $\mathbb{E}[C_i \mid C_1 = c_1, \dots, C_{i-1} = c_{i-1}] \leq 2\varepsilon^2$

לכן, לפי אזומה, לכל $z > 0$ מתקיים

$$\Pr_{v \leftarrow V} \left[\sum_{i=1}^k c_i(y_1, \dots, y_{i-1}, y_i) > k2\varepsilon^2 + z\sqrt{k}\varepsilon \right] \leq \exp\left(-\frac{z^2}{2}\right)$$

עבור $\hat{\delta} > 0$ נבחר $z = \sqrt{2 \cdot \ln(1/\hat{\delta})}$ ונסמן $\hat{\varepsilon} = 2k\varepsilon^2 + \sqrt{2k \cdot \ln(1/\hat{\delta})}\varepsilon$ ונקבל

$$\Pr_{v \leftarrow V} \left[\sum_{i=1}^k c_i(y_1, \dots, y_{i-1}, y_i) > \hat{\varepsilon} \right] \leq \hat{\delta}$$


מ.ש.ל. (משפט 2)

נותר להוכיח את טענת עזר 4.

אינטואיציה לגבי קומפוזיציה:

למה שהיציבות תתדרדר רק כמו \sqrt{k} ולא כמו k ?

נניח שאנחנו מריצים k פעמים את המכניזם הפלאסי על קלט S או על קלט שכן S' עם אותה שאילתא עם ערך 19 על S ועם ערך 20 על S' . בכל סיבוב נקבל דגימה מאחת מ-2 ההתפלגויות הבאות:



- נניח שאומרים לי שהריצו את המ.לפלאס על אחד מ- S, S' (נניח הערך האמיתי כל פעם הוא או 19 או 20), אבל אני לא יודע על מי מהם הריצו.
- אני רוצה לנסות לנחש האם הקלט הוא S או S'
- פלט < 19.5 "גורם לי לחשוב" ש- S' יותר סביר
- פלט > 19.5 "גורם לי לחשוב" ש- S יותר סביר
- אבל לפעמים נקבל פלט > 19.5 גם על S' , מה שרק מטעה אותי בניסיון להבחין בין S ל- S' (כלומר לפעמים גם "נרוויח יציבות")

עוד אינטואיציה: אז נניח שאנחנו מריצים את המ.לפלאס על S (כלומר דוגמים מההתפלגות הכחולה בציור הנ"ל). ברור שההסתברות שנקבל פלט קטן מ 19 היא בדיוק $1/2$. בנוסף, ההסתברות לקבל פלט בין 19 ל 19.5 היא בערך ε (אפשר לחשב את זה עם אינטגרל על פונק' הצפיפות). כלומר, ההסתברות שנקבל פלט באיזור בו הגרף הכחול גבוה מהסגול היא בערך $\varepsilon + \frac{1}{2}$, ובהסתברות בערך $\varepsilon - \frac{1}{2}$ נקבל פלט "שמטעה אותנו" שעבורו הגרף הסגול גבוה יותר.

מה יהיה מספר הפעמים שנקבל פלט "שלא מטעה אותנו"? זה משתנה מקרי עם התפלגות בינומית עם הסתברות הצלחה $\varepsilon + \frac{1}{2}$. התוחלת של מספר ההצלחות מתוך k דגימות היא $\frac{k}{2} + \varepsilon k$, כלומר בתוחלת יש באמת ייתרון מסויים לטובת "פלטים שלא מטעים אותנו". אבל סטיית התקן של משתנה מקרי כזה היא בערך $\frac{\sqrt{k}}{2}$. לכן אם $\varepsilon k \ll \frac{\sqrt{k}}{2}$ אז הייתרון שיש לנו "נבלע" בתוך סטיית התקן. כלומר, כל עוד $\varepsilon \ll \frac{1}{2\sqrt{k}}$ אז יהיה לנו מאוד קשה להבחין בין ההתפלגות הסגולה לכחולה.

אינטואיציה לגבי טענת עזר 4: בהוכחה הסתכלנו על המשתנה המקרי שמוגדר כך: נדגום נקודה y לפי ההתפלגות הכחולה, ואז נסתכל על לוג היחס בין הגובה של הקו הכחול לגובה של הקו הסגול. אנחנו כבר יודעים שלוג היחס הזה תמיד חסום עי $\pm \varepsilon$. אבל דיי ברור שהתוחלת של המשתנה המקרי הזו חייבת להיות הרבה יותר קטנה מ ε (כי לפעמים המספר הזה אפילו שלילי...). אפשר להראות שהתוחלת כאן היא בערך ε^2 .

נעשה את החשבון עבור המקרה של שני הלפליסים. כלומר נראה למה התוחלת קטנה מ $\varepsilon^2 \approx$ עבור הציור עם שני הגרפים כאשר אנחנו מניחים שהדטהבייס האמיתי הוא X עם ערך 19:

- $\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) = \varepsilon$ אם דוגמים ערך $y_i \leq 19$
- $\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) = -\varepsilon$ אם דוגמים ערך $y_i \geq 20$

- באמצע הוא בין לבין.. נניח לרעתנו שמתקיים $\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) = \varepsilon$ גם עבור $19 \leq y_i \leq 20$
- נשים לב שהסתברות להיות באמצע היא קטנה:

$$\begin{aligned} \Pr_{y_i \leftarrow M_i(S, p_i)} [19 \leq y_i \leq 20] &= \int_0^1 \frac{\varepsilon}{2} \cdot \exp(-\varepsilon \cdot y) dy = \left[\frac{\varepsilon}{2} \cdot \frac{\exp(-\varepsilon \cdot y)}{-\varepsilon} \right]_0^1 \\ &= \frac{1}{2} (1 - e^{-\varepsilon}) \approx \frac{1}{2} (1 - (1 - \varepsilon)) = \frac{\varepsilon}{2} \end{aligned}$$

- ולכן

$$\begin{aligned} \mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] &\leq \Pr[y_i \leq 19] \cdot \varepsilon + \Pr[19 < y_i < 20] \cdot \varepsilon + \Pr[y_i > 20] \cdot (-\varepsilon) \\ &\approx \frac{1}{2} \varepsilon + \frac{\varepsilon}{2} \varepsilon - \left(\frac{1}{2} - \frac{\varepsilon}{2} \right) \varepsilon = \varepsilon^2 \end{aligned}$$

הוכחה פורמלית של טענת עזר 4:

תחילה נשים לב שמתקיים

$$\mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] = \sum_{y_i} \Pr[M_i(S, p_i) = y_i] \cdot \ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \geq 0$$

הסבר: זה נובע מאי-שוויון *log-sum* שאומר שאם $a_1, \dots, a_n, b_1, \dots, b_n$ הם מספרים אי-שליליים אזי

$$\sum_i a_i \cdot \ln \left(\frac{a_i}{b_i} \right) \geq \left(\sum_i a_i \right) \cdot \ln \left(\frac{\sum_i a_i}{\sum_i b_i} \right)$$

$$\mathbb{E}_{y_i \leftarrow M_i(S', p_i)} \left[\ln \left(\frac{\Pr[M_i(S', p_i) = y_i]}{\Pr[M_i(S, p_i) = y_i]} \right) \right] \geq 0 \text{ גם מתקיים}$$

כעת,

$$\begin{aligned} &\mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] \leq \\ &\leq \mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] + \mathbb{E}_{y_i \leftarrow M_i(S', p_i)} \left[\ln \left(\frac{\Pr[M_i(S', p_i) = y_i]}{\Pr[M_i(S, p_i) = y_i]} \right) \right] \\ &= \mathbb{E}_{y_i \leftarrow M_i(S, p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] - \mathbb{E}_{y_i \leftarrow M_i(S', p_i)} \left[\ln \left(\frac{\Pr[M_i(S, p_i) = y_i]}{\Pr[M_i(S', p_i) = y_i]} \right) \right] \end{aligned}$$

$$\begin{aligned}
&= \sum_{y_i} \Pr_{M_i(S,p_i)}[y_i] \cdot \ln\left(\frac{\Pr[M_i(S,p_i) = y_i]}{\Pr[M_i(S',p_i) = y_i]}\right) - \sum_{y_i} \Pr_{M_i(S',p_i)}[y_i] \cdot \ln\left(\frac{\Pr[M_i(S,p_i) = y_i]}{\Pr[M_i(S',p_i) = y_i]}\right) \\
&= \sum_{y_i} \ln\left(\frac{\Pr[M_i(S,p_i) = y_i]}{\Pr[M_i(S',p_i) = y_i]}\right) \cdot \left(\Pr_{M_i(S,p_i)}[y_i] - \Pr_{M_i(S',p_i)}[y_i] \right) \\
&\leq \sum_{y_i} \left| \ln\left(\frac{\Pr[M_i(S,p_i) = y_i]}{\Pr[M_i(S',p_i) = y_i]}\right) \right| \cdot \left| \Pr_{M_i(S,p_i)}[y_i] - \Pr_{M_i(S',p_i)}[y_i] \right| \\
&\leq \max_{y_i \in \text{Supp}(Y_i)} \left| \ln\left(\frac{\Pr[M_i(S,p_i) = y_i]}{\Pr[M_i(S',p_i) = y_i]}\right) \right| \cdot \sum_{y_i} \left| \Pr_{M_i(S,p_i)}[y_i] - \Pr_{M_i(S',p_i)}[y_i] \right| \\
&\leq \varepsilon \cdot \sum_{y_i} \left| \Pr_{M_i(S,p_i)}[y_i] - \Pr_{M_i(S',p_i)}[y_i] \right| \stackrel{\text{ראו תזכורת למטה}}{=} \varepsilon \cdot 2 \cdot \text{SD}\left(M_i(S,p_i), M_i(S',p_i)\right) \\
&= 2\varepsilon \cdot \max_{T \subseteq \text{Supp}(Y_i)} \left| \Pr_{M_i(S,p_i)}[y_i \in T] - \Pr_{M_i(S',p_i)}[y_i \in T] \right| \stackrel{\substack{\leq \\ \text{נובע כי } M_i \\ \text{הוא DP יציב} \\ \text{(הסבר נוסף למטה)}}}{\leq} 2\varepsilon \cdot (1 - e^{-\varepsilon}) \leq 2\varepsilon^2
\end{aligned}$$

תזכורת: המרחק הסטטיסטי $\text{SD}(\mathcal{D}_1, \mathcal{D}_2)$ הוא מדד למרחק בין 2 התפלגויות $\mathcal{D}_1, \mathcal{D}_2$ ויש לו 2 הגדרות שקולות:

$$\text{SD}(\mathcal{D}_1, \mathcal{D}_2) = \frac{1}{2} \sum_y \left| \Pr_{x \sim \mathcal{D}_1}[x = y] - \Pr_{x \sim \mathcal{D}_2}[x = y] \right| = \max_T \left| \Pr_{x \sim \mathcal{D}_1}[x \in T] - \Pr_{x \sim \mathcal{D}_2}[x \in T] \right|$$

הסבר נוסף למעבר בשורה האחרונה: נסתכל על מאורע T הממקסם את הביטוי ונניח בה"כ כי

$$\Pr_{M_i(S,p_i)}[y_i \in T] \geq \Pr_{M_i(S',p_i)}[y_i \in T]$$

אזי, מכיוון ש- M_i הוא DP -יציב $(\varepsilon, 0)$ נקבל

$$\begin{aligned}
&\left| \Pr_{M_i(S,p_i)}[y_i \in T] - \Pr_{M_i(S',p_i)}[y_i \in T] \right| = \Pr_{M_i(S,p_i)}[y_i \in T] - \Pr_{M_i(S',p_i)}[y_i \in T] \leq \\
&\leq \Pr_{M_i(S,p_i)}[y_i \in T] - e^{-\varepsilon} \cdot \Pr_{M_i(S,p_i)}[y_i \in T] = (1 - e^{-\varepsilon}) \cdot \Pr_{M_i(S,p_i)}[y_i \in T] \leq (1 - e^{-\varepsilon})
\end{aligned}$$

מ.ש.ל. (טענת עזר 4). זה מסיים את ההוכחה של משפט הקומפוזיציה (משפט 2).

מסקנה 5: יהיו $0 < \varepsilon, \delta < 1$ ויהי $k \in \mathbb{N}$. נסמן $\gamma = \frac{\varepsilon}{\sqrt{8k \cdot \ln(1/\delta)}}$. אזי המכניזם $\vec{M}_{\text{Lap}}^{1/(\gamma n)}$ אשר מוגדר להיות הקומפוזיציה של k הפעלות של $M_{\text{Lap}}^{1/(\gamma n)}$ הוא (ε, δ) -DP-יציב (עבור k שאילתות).

הנקודה החשובה כאן היא שפרמטר היציבות מתדרדר רק כמו \sqrt{k} ולא לניארית עם k . כלומר, בצענו k הפעלות של מכניזמים שכל אחד מהם הוא (בערך) $\frac{\varepsilon}{\sqrt{k}}$ יציב, וקיבלנו מכניזם שהוא ε יציב.

טענה 6: יהיו $0 < \beta, \varepsilon, \delta < 1$, יהי $k \in \mathbb{N}$, ונסמן $\gamma = \frac{\varepsilon}{\sqrt{8k \cdot \ln(1/\delta)}}$. המכניזם $\vec{M}_{\text{Lap}}^{1/(\gamma n)}$ הוא (α, β) -מדוייק אמפירית עבור k שאילתות בהינתן מדגם בגודל n , כאשר

$$\alpha = \frac{1}{\gamma n} \cdot \ln\left(\frac{k}{\beta}\right) = O\left(\frac{\sqrt{k}}{\varepsilon n} \cdot \sqrt{\ln\left(\frac{1}{\delta}\right)} \cdot \ln\left(\frac{k}{\beta}\right)\right)$$

הוכחה

נזכור שעבור כל שאילתא q_i , המכניזם $\vec{M}_{\text{Lap}}^{1/(\gamma n)}$ מחזיר תשובה $q_i(S) + Y_i$ עבור $Y_i \sim \text{Lap}\left(\frac{1}{\gamma n}\right)$. לכן, כדי לחסום את השגיאה האמפירית מספיק לחסום את $\max_i |Y_i|$.

נקבע אינדקס i מסוים. כפי שראינו בשיעור הקודם, עבור $\alpha \geq \frac{1}{\gamma n} \cdot \ln\left(\frac{k}{\beta}\right)$ מתקיים:

$$\Pr[|Y_i| > \alpha] = \exp(-\gamma n \alpha) \leq \frac{\beta}{k}$$

לכן, לפי חסם האיחוד

$$\Pr\left[\max_i |Y_i| > \alpha\right] \leq \beta$$

מ.ש.ל. (טענה 6)

אז מה קיבלנו? המכניזם $\vec{M}_{\text{Lap}}^{1/(\gamma n)}$ הוא (ε, δ) -DP-יציב (עבור k שאילתות) והוא גם (α, β) -מדוייק אמפירית עבור

$$\alpha = O\left(\frac{\sqrt{k}}{\varepsilon n} \cdot \sqrt{\ln\left(\frac{1}{\delta}\right)} \cdot \ln\left(\frac{k}{\beta}\right)\right)$$

הנקודה החשובה כאן היא שהשגיאה מתנהגת רק כמו $\frac{\sqrt{k}}{n} \approx$ ולא כמו $\frac{k}{n} \approx$. זה אומר שמספר השאילתות k יכול להיות כמעט n^2 ועדיין נוכל להבטיח דיוק (אמפירי) לא טריוויאלי.

כדי להשלים את התמונה אנחנו צריכים להראות שאם מכניזם הוא גם (ε, δ) -DP-יציב וגם (α, β) -מדוייק אמפירית אז הוא מבטיח דיוק-סטטיסטי. לצורך כך אנחנו צריכים להכיר מכניזם (ε, δ) -DP-יציב נוסף

מכניזם NoisyArgmax

נניח שיש לנו אנליסט שקובע T שאילתות ומעוניין לזהות אחת מהן עם ערך גבוה (בעזרת מכניזם שהוא (ε, δ) -DP-יציב). אפשרות אחת שעומדת בפני האנליסט היא להעריך את כל אחת מ- T השאילתות האלה, נניח בעזרת מכניזם הלפלס, ולאחר מכן לבחור אחת שההערכה שלה הייתה גבוהה. אבל זה בזבזני כי האנליסט לא מעוניין ללמוד את הערך של כל השאילתות האלה...

NoisyAgrmax

1. Accept T queries q_1, q_2, \dots, q_T
2. For every $1 \leq t \leq T$ let $\hat{a}_t = q_t(S) + Y_t$ where $Y_t \sim \text{Lap}\left(\frac{2}{\epsilon n}\right)$
3. Return t such that $\hat{a}_t \geq \hat{a}_j$ for every j

אנחנו מניחים שהשאלות q_1, \dots, q_T שניתנות לאלגוריתם NoisyAgrmax הם שאילות עם רגישות $1/n$ (תזכורת: לפונקציה q יש רגישות $1/n$ אם שינוי של איבר אחד מהמדגם יכול לשנות את הערך האמפירי של q לכל היותר $1/n$. למשל, שאילתא סטטיסטית היא שאילתא עם רגישות $1/n$)

משפט 7: מכניזם NoisyAgrmax הוא $DP(\epsilon, 0)$ -יציב

הוכחה:

נקבע את השאלות q_1, \dots, q_T , נקבע שני מדגמים שכנים S, S' , ונקבע איבר $b \in \{1, 2, \dots, T\}$

עלינו להראות שמתקיים

$$\Pr[\text{NoisyAgrmax}(S) = b] \leq e^\epsilon \cdot \Pr[\text{NoisyAgrmax}(S') = b]$$

נזכור כי לכל שאילתא q_j אנחנו מוסיפים רעש $Y_t \sim \text{Lap}\left(\frac{2}{\epsilon n}\right)$. נסמן ב- \vec{Y}_{-b} את כל הרעשים חוץ מהרעש Y_b .

מספיר להראות כי לכל קביעה \vec{y}_{-b} של \vec{Y}_{-b} מתקיים

$$\Pr[\text{NoisyAgrmax}(S) = b | \vec{y}_{-b}] \leq e^\epsilon \cdot \Pr[\text{NoisyAgrmax}(S') = b | \vec{y}_{-b}]$$

כי אז

$$\Pr[\text{NoisyAgrmax}(S) = b] = \sum_{\vec{y}_{-b}} \Pr[\vec{y}_{-b}] \cdot \Pr[\text{NoisyAgrmax}(S) = b | \vec{y}_{-b}] \leq \dots$$

אז נקבע וקטור רעש \vec{y}_{-b} . עכשיו מתקיים

$$\Pr[\text{NoisyAgrmax}(S) = b | \vec{y}_{-b}] = \Pr\left[q_b(S) + \text{Lap}\left(\frac{2}{\epsilon n}\right) > \max_{j \neq b} \{q_j(S) + y_j\}\right]$$

$$= \Pr\left[q_b(S) + \frac{1}{n} + \text{Lap}\left(\frac{2}{\epsilon n}\right) > \max_{j \neq b} \left\{q_j(S) + \frac{1}{n} + y_j\right\}\right]$$

$$\leq \Pr\left[q_b(S) + \frac{1}{n} + \text{Lap}\left(\frac{2}{\epsilon n}\right) > \max_{j \neq b} \{q_j(S') + y_j\}\right]$$

$$\leq \Pr\left[q_b(S') + \frac{2}{n} + \text{Lap}\left(\frac{2}{\epsilon n}\right) > \max_{j \neq b} \{q_j(S') + y_j\}\right]$$

$$= \Pr\left[\text{Lap}\left(\frac{2}{n}, \frac{2}{\epsilon n}\right) > \max_{j \neq b} \{q_j(S') + y_j\} - q_b(S')\right] = ((1))$$

נזכור שפונקציות הצפיפות $h_{\mu,\lambda}$ ו- $h_{0,\lambda}$ של $\text{Lap}(0, \lambda)$ ושל $\text{Lap}(\mu, \lambda)$, בהתאמה, מקיימות

$$e^{-\mu/\lambda} \leq \frac{h_{0,\lambda}(x)}{h_{\mu,\lambda}(x)} \leq e^{\mu/\lambda}$$

ולכן

$$\begin{aligned} (1) &\leq e^\varepsilon \cdot \Pr \left[\text{Lap} \left(\frac{2}{\varepsilon n} \right) > \max_{j \neq b} \{q_j(S') + y_j\} - q_b(S') \right] \\ &= e^\varepsilon \cdot \Pr \left[q_b(S') + \text{Lap} \left(\frac{2}{\varepsilon n} \right) > \max_{j \neq b} \{q_j(S') + y_j\} \right] = e^\varepsilon \cdot \Pr[\text{NoisyAgrmax}(S') = b | \vec{y}_{-b}] \end{aligned}$$

טענה 8: אלגוריתם NoisyAgrmax מחזיר אינדקס t כך שבהסתברות לפחות $1 - \beta$ מתקיים

$$q_t(S) \geq \max_j \{q_j(S)\} - o \left(\frac{1}{\varepsilon n} \cdot \ln \frac{T}{\beta} \right)$$

(ההוכחה של טענה 8 דומה להוכחה של טענה 6)

DP-יציבות + דיוק-אמפירי גוררים דיוק-סטטיסטי

משפט 9: יהי M מכניזם אשר בהינתן מדגם בגודל $n = \Omega \left(\frac{1}{\varepsilon^2} \log \frac{1}{\delta} \right)$ עונה על k שאילות סטטיסטיות אדפטיביות כך ש-

א. M הוא (ε, δ) -DP-יציב

ב. M הוא (α, β) -מדויק-אמפירית

אזי M הוא $(\alpha + 10\varepsilon, \beta + \frac{k\delta}{\varepsilon})$ -מדויק-סטטיסטית.

מסקנה (משפט 9 + מכניזם הלפליס):

קיים מכניזם יעיל חישובית אשר בהינתן מדגם בגודל $n \gtrsim \frac{\sqrt{k}}{\alpha^2}$ עונה על k שאילות אדפטיביות עם דיוק סטטיסטי α .

בדומה למה שעשינו עם הנושא של דחיסת-טרנסקריפט, כדי להוכיח את משפט 9 אנחנו נוכיח את המשפט הבא:

משפט 10: יהי M מכניזם (ε, δ) -DP-יציב עבור k שאילות סטטיסטיות הפועל על מדגם בגודל $n = \Omega \left(\frac{1}{\varepsilon^2} \log \frac{1}{\delta} \right)$ אזי לכל אנליסט A , לכל התפלגות \mathcal{D} , ולכל $1 \leq i \leq k$ מתקיים

$$\Pr_{S \sim \mathcal{D}^n} \left[|q_i(S) - q_i(\mathcal{D})| > 10\varepsilon \right] < \frac{\delta}{\varepsilon}$$

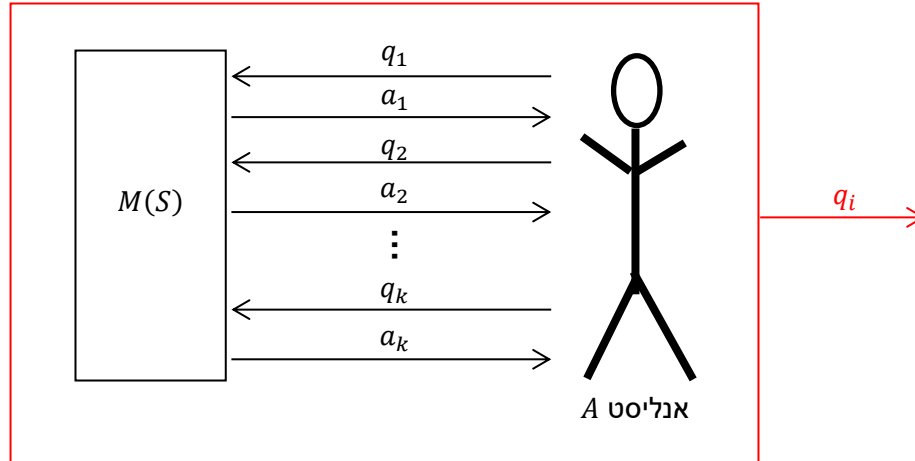
$AG_{n,k}(A,S,M)$

בדומה למה שראינו בנושא של דחיסת-טרנסקריפט, משפט 9 נובע ממשפט 10 ע"י שימוש בחסם האיחוד ובאי-שוויון המשולש.

לקראת ההוכחה של משפט 10:

נקבע אנליסט A , נקבע התפלגות \mathcal{D} ונקבע $1 \leq i \leq k$. נסמן ב- MA_i את המכניזם אשר בהינתן קלט S מסמלך את האינטראקציה בין A ל- M ובסיום האינטראקציה פולט את השאלת ה- i -ית q_i שהאנליסט שאל במהלך הריצה.

בציור:



$MA_i(S)$

זהו מכניזם אשר מקבל כקלט מדגם S ופולט שאלתא סטטיסטית q_i . בנוסף, מכיוון ש- M הוא DP-יציב, אנחנו יודעים שכל הטרנסקריפט בין A ל- M "לא רגיש" לשינויי של דגימה בודדת מהמדגם S . בפרט, גם ההתפלגות מעל q_i לא רגישה לשינויי של דגימה בודדת מהמדגם S . כלומר, MA_i הוא בעצמו DP-יציב. נח לנו לחשוב עליו כי אין שום אנליסט שמדבר איתו. הוא פשוט לוקח מדגם ואז פולט שאלתא.

כעת, במקום להוכיח את משפט 10, נוכל להוכיח את המשפט הבא:

משפט 11: יהי W מכניזם (ϵ, δ) -DP-יציב אשר מקבל כקלט מדגם S בגודל $n = \Omega\left(\frac{1}{\epsilon^2} \log \frac{1}{\delta}\right)$ ופולט שאלתא סטטיסטית q . אזי, לכל התפלגות \mathcal{D} מתקיים

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

נשים לב שמשפט 11 הוא פשוט יותר ממשפט 10: אין כאן מישהו ששואל שאלות ואין כאן סיבובים. רק מכניזם W שלוקח מדגם ומחזיר שאלתא. בנוסף, נשים לב שמשפט 10 נובע ממשפט 11, כי כמו שאמרנו, MA_i עומד בדרישות של משפט 11 ולכן התוצאה מתקיימת עבור השאלתא ה- i -ית.