

**תזכורת:**

**עצי HST-k** (הגדרה שונה במעט מזו שניתנה בשבוע שעבר) מרחב מטרי המוגדר על העלים של מושרש.

לכל צומת  $v$  משויכת תווית:

$$\Delta(v) \in \mathbb{R}^+$$

ברמה ה- $i$ ית בעץ:

$$\Delta(v) = \phi \cdot k^{-i}$$

לכל שני עלים  $x, y$ :

$$d(x, y) = \Delta(lca(x, y))$$

מעצם ההגדרה נוצר היררכי עם קוטר הולך וקטן.

**משפט:**

כל מרחב מטרי על  $n$  נקודות ניתן לשיכון ב-  $k$ -HST עם עיוות  $O(k \log_k n)$ .

**חלוקה הסתברותית:**  $(\lambda, \Delta)$

חלוקה של המרחב  $M = (V, d)$

לצבירים:  $c_1, c_2, \dots, c_n$

כאשר:

$$c_i \cap c_j = \emptyset$$

$$\bigcup_i c_i = V$$

$$\dim(c_i) \geq \Delta$$

$$\forall u, v: \Pr[u \in c_i \wedge v \in c_j, i \neq j] \leq \frac{\lambda}{\Delta} d(u, v)$$

**משפט מוחלש:**

בהינתן  $(\lambda, \Delta)$  חלוקות ל- $M$ , לכל  $\Delta$ .

אז המרחב ניתן לשיכון ב-  $k$ -HST עם עיוות:

$$O(k \lambda \log_k \phi)$$

הקוטר המנורמל של  $M$ . (הקוטר המקורי מחולק במרחק המינימאלי).  
 כאשר קוטר המסומן גם ב-  $d_{\text{aim}}$  זהו המרחק הגדול ביותר בין קודקודים במטריקה.

**הוכחת המשפט המוחלש:**

באינדוקציה על גודל המרחב.

**בסיס האינדוקציה:**  $n=1$ , הטענה טריוויאלית.

**שלב האינדוקציה:**



נבנה  $(\lambda, \Delta)$  חלוקה הסתברותית עם  $\Delta = \phi/k$ .

לכל צביר נבנה באופן רקורסיבי עץ  $k$ -HST:

$$T_1, T_2, \dots, T_n$$

(על פי הנחת האינדוקציה ניתן לעשות כן).

נקבל מצב המוצג בצורה הבאה:



מצב הצבירים.

לכל צביר בנינו עץ HST- $k$  המסומן במשולש.

כעת נחבר את עצי הצבירים לעץ אחד על ידי הוספת שורש  $r$ .  
נגדיר:

$$\Delta(r) = \phi = \text{diam}(M)$$

לפי הבנייה לכל (הרקורסיבית)  $i \leq t$ :

$$\Delta(r_i) = \text{diam}(c_i) \leq \phi / k$$

**הערה:** ניתן היה להגיע לשוויון.

כעת, עלינו להוכיח שני דברים (בכדי להראות שאכן קיבלנו חלוקה הסתברותית):

1. השיכון הוא אכן שיכון שאינו מכווץ.
2.  $E[d_T(u, v)] \leq [\lambda k \log_k \phi] \cdot d(u, v)$

**הוכחת 1:**

$$\Delta r = \text{diam}(M) \geq d(x, y) \quad \text{צ.ל.}$$

באופן אינדוקטיבי אם  $(x, y)$  היו באותו צביר אז המרחק שלהם קטן על פי הנחת האינדוקציה. אחרת, (הם בצבירים שונים):

$$d(x, y) = \Delta r = \phi$$

(גדל).

**הוכחת 2:**

ע"פ הנחת האינדוקציה:

$$E[d_T(u, v)] \leq [\lambda k \log_k \phi / k] \cdot d(u, v)$$

$$E(d_T(u, v)) \leq \Pr[u \in c_i \wedge v \in c_j, i \neq j] \cdot \phi + \Pr[u, v \in c_i] \cdot E[d_T(u, v)]$$

$$\leq \frac{\lambda}{\Delta} d(u, v) \cdot \phi + [\lambda k \log_k (\phi / k)] d(u, v)$$

$$\leq \frac{\lambda}{\phi / k} d(u, v) \cdot \phi + [\lambda k \log_k (\phi / k)] d(u, v)$$

$$= \lambda \cdot k \cdot d(u, v) + \log_k (\phi / k) \cdot \lambda \cdot k \cdot d(u, v)$$

$$= \lambda \cdot k \cdot d(u, v) [1 + \log_k (\phi / k)]$$

$$= [\lambda k \log_k \phi] \cdot d(u, v)$$

**למה:**

לכל מרחב מטרי על  $n$  נקודות,  $\forall \Delta > 0$ , יש  $(\log n, \Delta)$  חלוקה הסתברותית.

**הוכחה:**

בהינתן  $\Delta > 0$ :


נבחר נקודה כלשהי  $v_1 \in V$ ,

נבנה סביבה צביר (שהוא למעשה כדור) באופן הבא:  
נבחר רדיוס בהתפלגות שנקבע בהמשך.


ונגדיר:

$$C_1 = B(v_1, r_1)$$

נמשיך באותו אופן על תת המרחב שנותר:  $V - C_1$ ,  
(כלומר נבחר נקודה שאינה בכדור, ונבנה סביבה צביר)  
עד שנקבל חלוקה מלאה של כל המרחב לצבירים.



כעת נסביר מהי ההתפלגות של  $r$  (יתכן כי  $r > \Delta$  אח"כ נתקן):



נבחר את  $r$  להיות בקטע  $[\frac{(i-1)\Delta}{2\log n}, \frac{i\Delta}{2\log n}]$

בהסתברות  $1/2^i$ .

לאחר שקבענו באיזה קטע  $r$  יהיה, נבחר אותו בהסתברות אחידה מקטע זה.

נרצה להוכיח:

$$\forall u, v: \Pr[u \in c_i \wedge v \in c_j, i \neq j] \leq \frac{2\log n}{\Delta} d(u, v)$$


נוכל להסתכל רק על  $u, v$  המקיימים:

$$d(u, v) \leq \Delta / 2\log n$$

(על קואורדינאטות אחרות הטענה לא אומרת הרבה).

נניח בה"כ:

$$d(v_1, v) \geq d(v_1, u)$$



נחלק לשני מקרים :

**מקרה רע:**

ההסתברות ש-  $u, v$  מופרדים בשלב זה, זה הסיכוי ש-

$$d(v_1, u) < r \leq d(v_1, v)$$

$$d(v_1, v) - d(v_1, u) \leq d(u, v) < \frac{n}{2 \log n}$$

אי-שיויון המשולש

**מקרה טוב:**

$$r_1 \geq d(v_1, v)$$

$$\Pr[\text{מקרה רע בשלב } i] \leq \frac{1}{2^i} \cdot \frac{d(v_1, v) - d(v, u)}{\Delta / 2 \log n}$$

ההסתברות ש-  $u$  במעגל ו-  $v$  לא  
ההסתברות שנבחר הקטע ה- $i$  בו  
 $u, v$  נמצאים

$$\leq \frac{1}{2^i} \cdot \frac{2 \log n}{\Delta / 2 \log n} \cdot d(u, v)$$

ניתן להכליל את הטענה באופן לשלב ה- $j$  :

$$\Pr[\text{מקרה רע בשלב } j] \leq \frac{1}{2^j} \cdot \frac{d(v_j, v) - d(v, u)}{\Delta / 2 \log n}$$

ההסתברות ש-  $u$  במעגל ו-  $v$  לא  
ההסתברות שנבחר הקטע ה- $i$  בו  
 $u, v$  נמצאים (לאו דווקא אותו ה- $i$   
של שלב 1)

$$\leq \frac{1}{2^j} \cdot \frac{2 \log n}{\Delta} \cdot d(u, v)$$

$$\Pr[\text{מקרה טוב בשלב } j] \geq \sum_{l>i} \frac{1}{2^l}$$

נתעלם מן שייתכן ש- $r$  נופל בקטע  
ה- $i$ , ו- $i$  ואנו עדיין במקרה הטוב

$$\Pr[\text{מקרה רע בשלב } j] \leq \Pr[\text{מקרה טוב בשלב } j] \cdot \frac{2 \log n}{\Delta} \cdot d(u, v)$$

$$\Rightarrow \Pr[\text{מקרה רע}] \leq \Pr[\text{מקרה טוב}] \cdot \frac{2 \log n}{\Delta} \cdot d(u, v)$$

אם במהלך כל שלב היחס נשמר, אזי הוא נשמר גם בסופו של התהליך.

$$\Rightarrow \Pr [\text{מקרה רע}] \leq \frac{2 \log n}{\Delta} \cdot d(u, v)$$

$$\downarrow$$

$$\Pr [\text{מקרה טוב}] < 1$$

מדוע ההסתברות לכך שנבחר  $r \geq \Delta$  הינה קטנה מספיק?  
ההסתברות לכך היא:  
נסמן:  
 $i_\Delta = 2 \log n$

$$\frac{1}{2^{i_\Delta}} \leq \frac{1}{n^2}$$

וזאת עבור כל שלב.  
וכלן ע"פ חסם האיחוד נקבל שההסתברות שקיבלנו שאחד מן הרדיוסים שנבחר גדול מ- $\Delta$  הינה  $\frac{1}{n} \geq \frac{1}{n}$ . (ולכן בהסתברות קטנה יקרה מצב זה, ואם אכן יקרה נחזור על התהליך מחדש).

דוגמא לשימוש:

### Metric Labeling

נתונים:

1. קבוצה  $O$  של אובייקטים בגודל  $n$ .
2. קבוצה  $L$  של תוויות בגודל  $l$ .
3. יש מחיר השמה הנתון ע"י:  
 $\forall p \in O, \forall a \in L: c(p, a)$
4. מרחב מטרי על התוויות.
5. לכל שני אובייקטים  $p, q \in O$  יש משקל  $w_{pq}$ .

רוצים לתת תווית לכל אובייקט:


$$f: O \rightarrow L$$

באופן הבא:

$$\min \sum_{p \in O} c(p, f(p)) + \sum_{p, q \in O} w_{pq} d(f(p), f(q))$$

ניתן אלגוריתם 2 קירוב ל- $k$ -HST ( $k=2$ ).  
 נקבל אלגוריתם למטריקה כללית בקירוב  $O(\log(l))$ . (ע"י שיכון הסתברותי ב- $k$ -HST של מטריקת התוויות).

איזה סט תוויות נבחר  
 בתוך  $S_i$  המרחקים שווים.



קיבלנו רדוקציה לבעיית Metric Labeling במרחב יוניפורמי.  
 בעיה זו ניתן לפתור בעזרת תוכנית ה-LP.  
 ובעזרת הפתרון השיברי ניתן לבצע randomized rounding על מנת להגיע לפתרון בשלמים.