

מבנה נתונים ואלגוריתמים - הרצאה 12

6 בדצמבר 2011

דוחיסה

תחליה עוסק בדוחיסה שהיא Lossless - לא מאבדים מידע בדוחיסה.

טענה

כל דוחיסה מגדילה חלק מהקבצים.

הוכחה

נניח שקיימת דוחיסה שמטקינה או משאירת שווה כל קובץ:

$$f : L \rightarrow K$$

ותמיד $k \leq L$.

ניקח את m להיות גודל הקובץ המינימלי שעובר דוחיסה ממש.

קיים קובץ בגודל m שעובר לנודל m_1 כאשר $m_1 < m$.

יש 2^{m_1} קבצים אפשריים בגודל m_1 . לאחר הדחיסה יש לפחות $1 + 2^{m_1}$ קבצים אפשריים בגודל m_1 . לפיכך קובץ אחד מופיע פעמיים בקבצים בגודל m_1 . لكن קיימים שני קבצים שונים שננדחסים לאותו קובץ, בנויגוד לעובדה שהדוחיסה ללא הפסד.

אי שוויון גיבס

מכאן והלאה - p_i, q_i הן התפלגות:

$$\begin{aligned} q_i, p_i &> 0 \\ \sum_i p_i &= 1 \\ \sum_i q_i &= 1 \end{aligned}$$

אי שוויון גיבס אומר: לכל p, q :

$$-\sum_i p_i \log(p_i) \leq -\sum_i p_i \log(q_i)$$

נשים לב שצד שמאל הוא אנטרופיה:

$$H = -\sum_i p_i \log(p_i)$$

אפשר לכתוב אחרת:

$$\begin{aligned} -\sum_i p_i [\log(p_i) - \log(q_i)] &\leq 0 \\ -\sum_i p_i \log\left(\frac{p_i}{q_i}\right) &\leq 0 \end{aligned}$$

הוכחה

$$\begin{aligned}
 -\sum_i p_i \log \left(\frac{p_i}{q_i} \right) &\leq \sum_i p_i \log \left(\frac{q_i}{p_i} \right) \\
 &\leq \sum_i p_i \left(\frac{q_i}{p_i} - 1 \right) \\
 &= \sum_i q_i - \sum_i p_i = 0
 \end{aligned}$$

השתמשנו בכך ש $\ln x \leq x - 1$

$$\begin{aligned}
 f(x) &= x - 1 - \ln x \\
 f'(x) &= 1 - \frac{1}{x} = 0 \\
 x &= 1 \\
 f(1) &= 0 \\
 f(x) &\geq 0 \\
 \ln x &\leq x - 1
 \end{aligned}$$

לכן אי השוויון נכון.
אם נגיד

$$D(p, q) = \sum_i p_i \log \left(\frac{p_i}{q_i} \right) \geq 0$$

ומתקיים:

$$D(p, q) = 0 \iff p = q$$

לכן זו סמי-מטריקה זו לא מטריקה כי אין סימטריות.
 $D(p, q)$ נקרא מרחק קולבק-לייבר.
יש גם מקבילה רציפה למרחק זה:

$$D(p, q) = \int p(x) \log \left(\frac{p(x)}{q(x)} \right) dx$$

אי שוויון Kraft - קוד רישא

קוד רישא הוא קוד שבו אף מילה אינה רישא של מילה אחרת, שבאלפבית שלו יש D אותיות.
בහינתו קוד רישא יש לכל מילה אורך ℓ_i .
אי שוויון Kraft הוא:

$$\sum_i D^{-\ell_i} \leq 1$$

הוכחה

נכתוב את קוד הרישא בעץ - מיילים הן עליים.
נסמן ב k את עומק העץ.
נמלא את העץ עד עומק k , כולמר נוסיף לעליים בניים עד עומק k , ו"נסמן" את הבנים שהוספנו ושלא באמות שיעיכים לעץ המקורי.
מתוחת לכל מילה אורך ℓ_i יש $D^{k-\ell_i}$ עליים.
יש בסה"כ D^k עליים בעץ (כי זה עץ מלא בעומק k ולכל צומת יש D בניים).
נעבור על כל המיללים וניקח את כל העליים שיש מתחתיה אליהם בעץ, וזה בהכרח לכל היותר מס' העליים בעץ:

$$\sum_i D^{k-\ell_i} \leq D^k$$

מחלק ב- D^k ונקבל:

$$\sum_i D^{-\ell_i} \leq 1$$

מש.ל.

טענה

יהי ℓ אורך המילים בקוד רישא, אז:

$$\sum_i p_i \ell_i \geq H$$

כאשר H היא האנטרופיה.

הוכחה

נגדיר

$$\begin{aligned} z &= \sum_i 2^{-\ell_i} \leq 1 \\ q_i &= \frac{2^{-\ell_i}}{z} \end{aligned}$$

נשים לב ש q_i היא התפלגות:

$$\begin{aligned} q_i &\geq 0 \\ \sum_i q_i &= \frac{\sum_i 2^{-\ell_i}}{z} = \frac{z}{z} = 1 \end{aligned}$$

מעבר אנפחים ונקבל:

$$\begin{aligned} 2^{-\ell_i} &= z \cdot q_i \\ \ell_i &= -\log_2 z - \log_2 q_i \end{aligned}$$

אזי

$$\begin{aligned} \sum_i p_i \ell_i &= -\sum_i p_i \log_2 z - \sum_i p_i \log_2 q_i \\ &= -\log_2 z - \sum_i p_i \log_2 q_i \\ &\geq 0 - \sum_i p_i \log_2 p_i = H \end{aligned}$$

(המעבר לשורה الأخيرة הוא לפי Kraft ו-Gibbs).
לכן בעצם אלגוריתם הדחיסה המכטב בקוד רישא יידחס עד גבול H .
נשים לב שם אנו רוצים שהאלגוריתם יפעל כך, אנו צריכים שיטקיקים:

$$\begin{aligned} \log_2(z) &= 0 \\ p_i &\sim q_i \end{aligned}$$


כולם התנאים שרצחה שיטקיקימו הם:

$$\begin{aligned} \log_2(z) &= 0 \\ p_i &\sim \frac{2^{-\ell_i}}{z} \end{aligned}$$

קוד הופמן

נשים לב שאם יש לנו עץ שלם (כלומר לא קיים צומת עם בן יחיד), יתקיים בהכרח $0 = \log_2 z$, כי

$$\sum 2^{-\ell_i} = 1$$




קוד הופמן תמיד יתן לנו עץ שלם, ולכן התנאי הראשון תמיד יתקיים בו.

ננית לדוגמה שאלה המילים והשכיחויות:

| מילה | שכיחות |
|----------------|--------|
| $\frac{1}{2}$ | a |
| $\frac{1}{4}$ | b |
| $\frac{1}{8}$ | c |
| $\frac{1}{16}$ | d |
| $\frac{1}{16}$ | e |

העץ שנתקבל מקוד הופמן הוא:



או נקבל:

| מילה | שכיחות | המילה בקוד הופמן | ℓ_i |
|------|----------------|------------------|----------|
| a | $\frac{1}{2}$ | 0 | 1 |
| b | $\frac{1}{4}$ | 10 | 2 |
| c | $\frac{1}{8}$ | 110 | 3 |
| d | $\frac{1}{16}$ | 1110 | 4 |
| e | $\frac{1}{16}$ | 1111 | 4 |


אזי במקרה זה $z = 2^{-1} + 2^{-2} + 2^{-3} + 2 \cdot 2^{-4} = 1$ וזה יקטאים בכל מקרה בקוד הופמן.

אך התנאי השני לא בהכרח יתקיים, למרות שפה הוא כן מתקיים.

אם השכיחויות לא יהיו חזקות של 2 או מושהו קרוב אליו, יכול להתקבל משהו שונה:

| מילה | שכיחות |
|------|---------------|
| a | $\frac{1}{3}$ |
| b | $\frac{1}{3}$ |
| c | $\frac{1}{9}$ |
| d | $\frac{2}{9}$ |
| e | 0 |

אז הופמן שנתקבל:



(אך:

| מילה | שכיחות | קוד הופמן | אורך |
|------|---------------|-----------|------|
| a | $\frac{1}{3}$ | 00 | 2 |
| b | $\frac{1}{3}$ | 01 | 2 |
| c | $\frac{1}{9}$ | 110 | 3 |
| d | $\frac{2}{9}$ | 10 | 2 |
| e | 0 | 111 | 3 |

ובמקרה זה התנאי השני לא מתקיים.