

D

למה אנחנו

- למה אנחנו נעשה את זה? למה?
- למה אנחנו נעשה את זה?
- למה אנחנו נעשה את זה?

מה זה? מה זה?
 קשתות צופות - בעיית אמינות
 קשתות חסרות - למה אנחנו נעשה את זה?

הבעיה: יש $2^{O(n)}$ אפשרויות!

שיטות אלטרנטיביות:

(III) מיון ציון (Score)
 + מוסיפים סטטיסטיקה
 + פשרות
 + לוקח בחשבון את ה-
 - יקר (אבל פחות מ-II)

(II) ב"ס יאני
 קשה חישובית

(I) אילו צימ
 מבנים סטטיסטיים
 + אנונימיות
 - רבים למה?

ציון הנכונות Likelihood Score

$$\begin{aligned}
 L(G; D) &= \max_{\theta_G} \log P(D|G, \theta_G) = \\
 &= \sum_m \log P_{\theta}^{\hat{}}(X[m]) = \sum_m \sum_i \log P_{\theta}^{\hat{}}(X_i[m] | p_{ai}[m]) \\
 &= \sum_i \sum_{p_{ai}} \sum_{x_i} \underbrace{M[X_i, p_{ai}]}_{\text{כוכב}} \cdot \log \theta_{x_i | p_{ai}}
 \end{aligned}$$

2)

$$= \sum_i \sum_{p_{oi}} \sum_{x_i} [\log \hat{P}(x_i | p_{oi})] \cdot M[x_i, p_{oi}]$$

$$= M \sum_i \sum_{p_{oi}} \sum_{x_i} \hat{P}(x_i, p_{oi}) \log \hat{P}(x_i | p_{oi}) \cdot \frac{\hat{P}(x_i)}{\hat{P}(x_i)}$$

$$= M \sum_i \sum_{p_{oi}} \sum_{x_i} \left[\underbrace{\hat{P}(x_i, p_{oi}) \log \frac{\hat{P}(x_i, p_{oi})}{\hat{P}(p_{oi}) \hat{P}(x_i)}}_{\hat{I}(x_i; p_{oi})} + \underbrace{\hat{P}(x_i, p_{oi}) \log \hat{P}(x_i)}_{-\hat{H}(x_i)} \right]$$

$$= M \left[\underbrace{\sum_i \hat{I}(x_i; p_{oi})}_{\substack{\text{אינפורמציה בט} \\ \text{מסמך}}} - \underbrace{\hat{H}(x_i)}_{\substack{\text{אנטי-} \\ \text{אנטי-}}}$$

מה זה טאג? - הציון מתפרק (צדד לחיטה)
 - קל לטאג טאג

מה הטאג? $I(x; y, z) \geq I(x; y)$ אינפורמציה רק בטאג.
 מה המשמעות?

בתחילת אלברט:

- מדדים מרחב חרוט (NB, TAN)
 - סקור את ה-score

3

Bayesian Score

$$P(G|D) = \frac{P(D|G)P(G)}{P(D)}$$

נתחם קבוצת המילים

$$\text{score}_B(G;D) = \log P(D|G) + \log P(G)$$

marginal likelihood

prior (מקור משייט)

$$P(D|G) = \int_{\theta_G} P(D|G, \theta_G) P(\theta_G|G) d\theta$$

מחפשים את פני המטריים. מה פה שאומר?

$$= \prod_{m=1}^M P(X[m] | X[1] \dots X[m-1])$$

צורה סדרתית

למה הצורה הזאת? (קבוצת מונות)

sequential form

$$\frac{1}{M} \log P(D|G) \approx E_{p^*} [\log P(X|G,D)]$$

אנחנו ניסו להטות את הממוצע

אנחנו מניחים

$$D = \langle H, T, T, H, H \rangle$$

נתחם במספרה בתנאים

$$P(D) = P(X[1])P(X[2]|X[1]) \dots$$

$$= \prod_{m=1}^M P(X[m]|X[1] \dots X[m-1]) = \int_{\theta} P(X[1]|G) P(\theta|G) \dots P(X[M]|G) P(\theta|G) d\theta$$

האילו כבר הזכרנו פה מונות ציבורית

$$= \frac{\alpha_1}{\alpha} \cdot \frac{\alpha_0}{\alpha+1} + \frac{\alpha_0+1}{\alpha+2} \cdot \frac{\alpha_1+1}{\alpha+3} \cdot \frac{\alpha_1+2}{\alpha+4} = \frac{[\alpha_1(\alpha_1+1)(\alpha_1+2)] [\alpha_0(\alpha_0+1)]}{\alpha(\alpha+1) \dots (\alpha+4)}$$

④

$$P(X[1] \dots X[m]) = \frac{[\alpha_1(\alpha_1+1) \dots \alpha_1+M[1]-1][\alpha_0 \dots (\alpha_0+M[0]-1)]}{\alpha(\alpha+1) \dots \alpha+M-1} \cdot \text{הכפלה}$$

$$\Gamma(m) = (m-1)!$$

$$\Gamma(x+1) = x\Gamma(x)$$

$$\Gamma(\alpha) = \int_0^\infty t^{\alpha-1} e^{-t} dt$$

$$= \frac{\Gamma(\alpha_1 + M[1])}{\Gamma(\alpha_1)} \cdot \frac{\Gamma(\alpha_0 + M[0])}{\Gamma(\alpha_0)} \cdot \frac{\Gamma(\alpha)}{\Gamma(\alpha+M)}$$

$$\log P(D) = \log \Gamma(\alpha) - \log \Gamma(\alpha+M) + \sum_{i=1}^k \left[\log \Gamma(\alpha_i + M[X_i=i]) - \log \Gamma(\alpha_i) \right]$$

הכפלה למינימום

וכפול, זה לא תלוי בסדר התצפיות.

הכפלה מרוב מינימום x y-1 בי"י

$$P(D | G_\phi) = \int_{\theta_x, \theta_y} P(\theta_x, \theta_y | G_\phi) P(D | G_\phi, \theta_x, \theta_y) d[\theta_x, \theta_y]$$

$$\begin{aligned} &= \left(\int_{\theta_x} P(\theta_x | G_\phi) \prod_m P(X[m] | \theta_x, G_\phi) d\theta_x \right) \\ &\times \left(\int_{\theta_y} P(\theta_y | G_\phi) \prod_m P(X[m] | \theta_y, G_\phi) d\theta_y \right) \end{aligned}$$

קולטו תנאי התנאי פה
 B
 תנאי
 פה
 תנאי
 תנאי
 תנאי
 תנאי

3

כמה דוגמאות

$$P(D|G_{x \rightarrow y}) = \left(\int_{\theta_x} \text{כמה דוגמאות} \right)$$

$$\times \left(\int_{\theta_{y|x=0}} P(\theta_{y|x=0} | G_{x \rightarrow y}) \prod_{m: X[m]=0} P(y[m] | \theta_{y|x=0}) \cdot d\theta_{y|x=0} \right)$$

$$\times \left(y|x=1 \text{ כמה דוגמאות} \right)$$

$$\alpha_{par_i} = \sum_{x_i} \alpha_{x_i | par_i}$$

כמה דוגמאות: $P(D|G) = \prod_i \prod_{par_i} P(D_i | D_{par_i}, G)$

$$\log P(D|G) = \sum_i \sum_{par_i} \left[\log \frac{\Gamma(\alpha_{par_i})}{\Gamma(\alpha_{par_i} + M[par_i])} + \sum_{x_i} \log \frac{\Gamma(\alpha_{x_i | par_i} + M[x_i])}{\Gamma(\alpha_{x_i | par_i})} \right]$$

כמה דוגמאות: $\Gamma(x) \approx \sqrt{2\pi} x^{(x-1/2)} \cdot e^{-x}$ בעזרת קרוב סטטיסטי

$$\log P(D|G) \approx \underbrace{\ell(\hat{\theta}_G; D)}_{\text{כמה דוגמאות}} - \frac{1}{2} \log M \cdot \underbrace{\text{Dim}(G)}_{\text{מספר משתנים}} + o(1)$$

מה המשמעות?

6

הנחה: ρ^* נתון והוא מתקן

G^* הוא p -map. score -ה של G^* הוא קונסיסטנט עבור $M \rightarrow \infty$ ולכן:

(1) G^* הוא הציון הנכון ביותר.

(2) לכל G אחר, score -ה של G נמוך יותר.

לכן: BIC הוא קונסיסטנטי

(I) נניח G אינו G^* . קיימת הפרש $\epsilon > 0$ בין $\sum_i I_{p^*}(x_i; \rho_i^{G^*})$ ל- $\sum_i I_{p^*}(x_i; \rho_i^G)$ עבור p כלשהו.

(II) עבור G נתון, ρ^* הוא הציון הנכון ביותר עבור G^* . G אינו G^* ולכן ρ^* אינו מתאים ל- G .

כאשר $\hat{\rho} \rightarrow \rho^*$, $M \rightarrow \infty$ ונקבל

$$\text{score}_L(G^*; \rho) \rightarrow \text{score}_L(G; \rho) \rightarrow 0$$

$$\Delta BIC = \frac{1}{2} [\text{Dim}(G) - \text{Dim}(G^*)] \log M > 0 \quad \text{לכן}$$

Bayesian Score is consistent \Leftarrow