



האוניברסיטה  
העברית  
בירושלים  
THE HEBREW  
UNIVERSITY  
OF JERUSALEM

# אלגוריתמים בביו' חישובית

76558

למידת פרמטרים במודלים  
מרקוביים חבויים

תומי קפלן

6/2/2024

# למידת פרמטרים במודל מרקובי חבוי

דיברנו על חישובי ניראות והסקה. אבל מאיפה המודל?

- לימוד מבנה - נגענו טיפה. מורכב. יצירתיות וסבלנות.

- לימוד פרמטרים - נניח סט אימון של רצפים ב"ת

$$LL(\theta : D) = \log P(\vec{X}^1, \dots, \vec{X}^N | \theta) = \sum_{j=1}^N \log P(\vec{X}^j | \theta)$$

$\theta$  סט הפרמטרים של המודל: transitions :  $\tau_{k,l}$

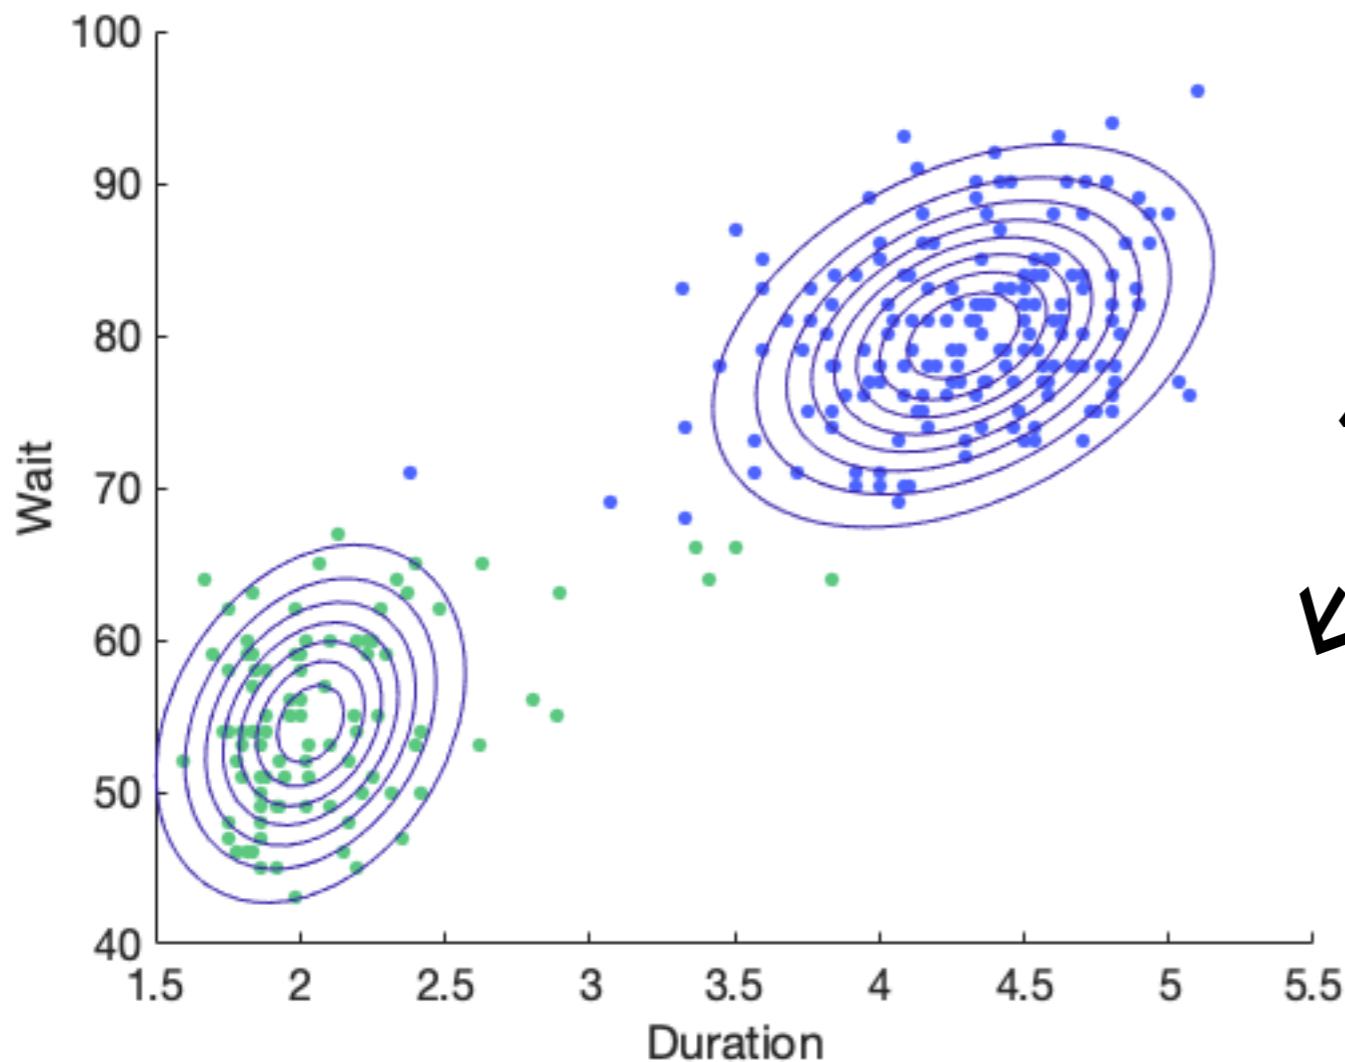
emissions :  $e_L(k)$

- אז איך לומדים את הפרמטרים האופטימליים?  
[הרי המצבים החבויים חבויים]

# לא מאוד שונה מבעיות שראינו בעבר

- למשל, בעיית הקלאסטרינג - קיבוץ דוגמאות לסוגים

## Gaussian Mixture Model



- תיוג הדוגמאות חסר

- אלגוריתם K-means:

שייך דוגמא לקלאסטר ↶

שערוך המרכזים מחדש ↷

השלמת המידע ע"ס התצפיות והפרמטרים הקיימים


# קלאסטריןג בגירסא רנה

- כל נקודה משוייכת לכל מרכז, בהסתברות כלשהי (ההסת' א-פוסטריורי, להגיע מכל אחד מהמרכזים)

- אלגוריתם רד:

הנידאות והפוסטריור  
לפי כל קלאסטר

ממוצע ושונות של כל  
קבוצה, ממושקלים לפי  
השיוך



נחפש אלגוריתם דומה למודלים מרקוביים חבויים

# למידת פרמטרים במודל מרקובי חבוי

- נניח לדגם שהדאטה היה מתוייג כולו

$$\begin{aligned} LL(\theta : D^*) &= \sum_{j=1}^N \log P(\vec{X}^j, \vec{S}^j | \theta) \\ &= \sum_{j=1}^N \sum_{i=1}^{n_j} \left[ \log P(S_i^j | S_{i-1}^j) + \log P(X_i^j | S_i^j) \right] \\ &= \sum_{j=1}^N \sum_{i=1}^{n_j} \left[ \log \tau_{S_{i-1}^j, S_i^j} + \log e_{S_i^j}(X_i^j) \right] \\ &= \sum_{k,l} N_{k,l} \cdot \log \tau_{k,l} + \sum_{k,x} N_{k,x} \cdot \log e_k(x) \end{aligned}$$

- קל לגזור ולמצוא את  $\theta$  שממקסמת את לוג הניראות

# למידת פרמטרים במודל מרקובי חבוי

- אבל אין לנו מידע מתויג אודות המסלולים  $\{\vec{S}^j\}$
- הנראות דורשת סכימה על כל ההשמות האפשריות

$$L(\theta : D^*) = \prod_{j=1}^N P(\vec{X}^j | \theta) = \prod_{j=1}^N \sum_{\vec{S}^j} \prod_{i=1}^{N_j} \left[ \tau_{S_{i-1}^j, S_i^j} \cdot e_{S_i^j}(X_i^j) \right]$$

- ואנו מחפשים את  $\theta$  הממקסמת את [לוג] הנראות

$$\theta^* = \arg \max_{\theta} L(\theta : D) = \arg \max_{\theta} LL(\theta : D) = \sum_{j=1}^N \log P(\vec{X}^j | \theta)$$

# מה נעשה?

- **מציאת מסלולי ויטרבי  $\Leftrightarrow$  שערוך פרמטרים**

- **אופטימיזציה מבוססת גרדיאנט**  
נאתחל את  $\theta$  ונבצע שינויים קטנים לשיפור הניראות,  
עד להתבנסות [לאופטימום לוקאלי]

- **אלגוריתם באום-וולש [Baum-Welch]**

אלגוריתם דו-צדדי.

צעד  $E$  משערך תוחלות על המסלולים החבויים\*

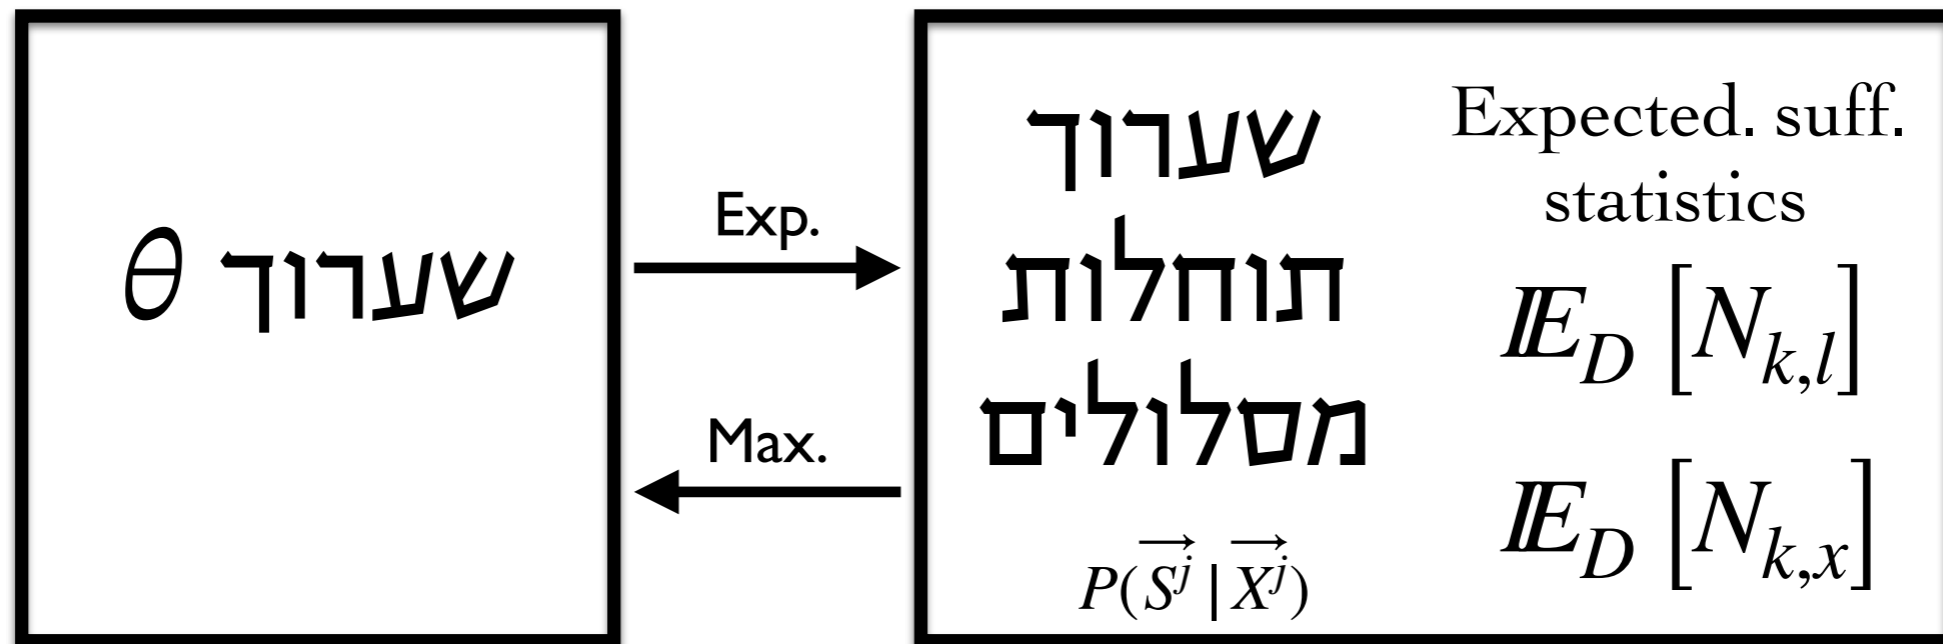
צעד  $M$  משערך את הפרמטרים על פיהם

ועל הסטטיסטי המספיקים\*

# Expectation-Maximization

• אלגוריתם באום-וולש [Baum-Welch] אלגוריתם דו-צדדי.

צעד E משערך תוחלות על המסלולים החבויים\*  
צעד M משערך את הפרמטרים על פיהם





# שערוך MLE לפרמטרים

- ניזכר בסטטיסטי המספיקים לאומדי MLE

$$\tilde{\tau}_{k,l} = \frac{N_{k,l}}{\sum_m N_{k,m}} \quad \tilde{e}_k(x) = \frac{N_{k,x}}{\sum_y N_{k,y}}$$

- כאשר

$$N_{k,l} = \sum_{j=1}^N \sum_{i=2}^{n_j} \mathbb{1} \{S_{i-1}^j = k, S_i^j = l\} \quad N_{k,x} = \sum_{j=1}^N \sum_{i=1}^{n_j} \mathbb{1} \{S_i^j = k, X_i^j = x\}$$

- כאשר  $\{S^j\}$  לא ידוע, נסתפק בתוחלות

$$\tilde{N}_{k,l} = \sum_{j=1}^N \sum_{i=2}^{n_j} E_\theta \mathbb{1} \{S_{i-1}^j = k, S_i^j = l\} \quad \tilde{N}_{k,x} = \sum_{j=1}^N \sum_{i=1}^{n_j} E_\theta \mathbb{1} \{S_i^j = k, X_i^j = x\}$$

# שערוך MLE לפרמטרים

• כאשר  $\{S^j\}$  לא ידוע, נסתפק בתוחלות

$$\begin{aligned}\tilde{N}_{k,l} &= \sum_{j=1}^N \sum_{i=2}^{n_j} E_{\theta} \mathbb{1} \{S_{i-1}^j = k, S_i^j = l\} \\ &= \sum_{j=1}^N \sum_{i=2}^{n_j} P(S_{i-1}^j = k, S_i^j = l | \vec{X}^j) \\ &= \sum_{j=1}^N \sum_{i=2}^{n_j} \frac{[F_k(i-1) \cdot \tau_{k,l} \cdot \mathbf{e}_l(X_i) \cdot B_l(i)]}{P(\vec{X}^j)}\end{aligned}$$

$$\begin{aligned}\tilde{N}_{k,x} &= \sum_{j=1}^N \sum_{i=1}^{n_j} E_{\theta} \mathbb{1} \{S_i^j = k, X_i^j = x\} \\ &= \sum_{j=1}^N \sum_{i=1}^{n_j} \left[ P(S_i^j = k | \vec{X}^j) \cdot P(X_i^j = x | S_i^j = k, \vec{X}^j) \right] = \sum_{j=1}^N \sum_{i: X_i^j = x} P(S_i^j = k | \vec{X}^j) \\ &= \sum_{j=1}^N \sum_{i: X_i^j = x} \frac{F_k(i) \cdot B_k(i)}{P(\vec{X}^j)}\end{aligned}$$

# אלגוריתם באוס-וולש

- אתחול  $\theta$  [רנדומית]

- בכל איטרציה  $t$

- לכל רצף  $X^j$  חשבו את הפורוורד והבקוורד [בעזרת  $\theta$  הנוכחית]

- שלב E: 
$$\tilde{N}_{k,l} = \sum_{j=1}^N \sum_{i=2}^{n_j} [F_k(i-1) \cdot \tau_{k,l} \cdot e_l(X_i) \cdot B_l(i)] \quad \tilde{N}_{k,x} = \sum_{j=1}^N \sum_{i: X_i^j = x} \frac{F_k(i) \cdot B_k(i)}{P(\vec{X}^j)}$$

- שלב M: 
$$\tilde{\tau}_{k,l} = \frac{N_{k,l}}{\sum_m N_{k,m}} \quad \tilde{e}_k(x) = \frac{N_{k,x}}{\sum_y N_{k,y}}$$

- עיצרו אם השיפור בלוג הנדאות [או אם השינוי ב-  $\theta$ ] קטן מספיק

# הבסיס התיאורטי ל-EM

- נסתכל על לוג הנראות [כפונקציה של  $\theta$ ]

$$LL(\theta : D) = \sum_j LL(\theta : D^j) = \sum_j \log P(X^j | \theta) = \sum_j \log \sum_{S^j} P(X^j, S^j | \theta)$$

$$= \sum_j \log \sum_{S^j} Q(S^j) \cdot \left[ \frac{P(X^j, S^j | \theta)}{Q(S^j)} \right] \triangleq \sum_j \log \mathbb{E}_Q \frac{P(X^j, S^j | \theta)}{Q(S^j)}$$


$$\stackrel{\text{Jensen}}{\geq} \sum_j \mathbb{E}_Q \log \frac{P(X^j, S^j | \theta)}{Q(S^j)} = \sum_j \mathbb{E}_Q [LL(\theta)] - \sum_j \sum_{S^j} Q(S^j) \log Q(S^j)$$

$$= \sum_j \mathbb{E}_Q [LL(\theta)] + \sum_j H(Q) \geq \sum_j \mathbb{E}_Q [LL(\theta)]$$

- כלומר סכום התוחלות לפי  $Q$  חוסם את לוג הנראות מלמטה


# אי-שוויון ינסן

- אי-שוויון ינסן: ממוצע ערכי פונקציה **קמורה** גדול/שווה לערך הפונקציה בממוצע הנקודות.



$$\mathbb{E}[f(x)] \geq f(\mathbb{E}[x]) \quad f''(x) \geq 0$$


- ולחלופין, ממוצע ערכי פונקציה **קעורה** קטן/שווה לערך הפונקציה בממוצע הנקודות.



$$\mathbb{E}[g(x)] \leq g(\mathbb{E}[x]) \quad g''(x) \leq 0$$

- פונקצית הלוג **קעורה**  $\frac{d^2 \log x}{dx^2} = \frac{-1}{x^2} \leq 0$

- ולפיכך  $\mathbb{E}[\log(x)] \leq \log(\mathbb{E}[x])$



- כמובן שיתקיים שיוויון אם  $f$  לינארית או קבועה

# הבסיס התיאורטי ל-EM

- נחזור לחסם לוג הנראות בעזרת  $Q$

$$LL(\theta) = \overset{\text{Jensen}}{\geq} \sum_j \mathbb{E}_Q [LL(\theta)] + \sum_j H(Q)$$

- איזה  $Q$  נבחר?

- נחפש  $Q$  עבורה  $\frac{P(X^j, S^j | \theta)}{Q(S^j)}$  קבוע. כלומר  $Q(S^j) \propto P(X^j, S^j | \theta)$

- למשל הפוסטריוור:  $P(X^j, S^j | \theta) = P(S^j | X^j, \theta) \cdot P(X^j | \theta)$

- ואז יתקיים:  $LL(\theta) = \mathbb{E}_Q [LL(\theta)] + H(Q) \triangleq F_D [\theta, Q]$

$\mathbb{E}_Q[LL]$  נוחה למיקסום, וחוסמת את לוג הנראות מלמטה

# הבסיס התיאורטי ל-EM

- נסכם.

- מדי צעד נעדכן את  $Q$  להיות הפוסטריוור לפי  $\theta$  הנוכחית

$$\text{E-step : } Q(S^j) = P(S^j | X^j, \theta)$$

- ואת  $\theta$  למקסם את  $E_Q[LL]$  ובתוך כך לוג הניראות לפי  $\theta$

$$\text{M-step : } \tilde{\theta} = \arg \max_{\theta} \sum_j \mathbb{E}_Q \log P(X^j | \theta)$$

- בד"כ EM יתכנס תוך 5-10 איטרציות למקסימום לוקאלי