

## אומדן פרמטרים $\theta$ של מודל חבוי ללא נתונים מתוייגים (unsupervised)

מטרה: שערך של  $\theta_{ML}$ , בהינתן מדגם של  $N$  תצפיות בלתי תלויות  $y = y_1, \dots, y_N$ :

$$\theta_{ML} = \underset{\theta}{\operatorname{argmax}} P(y; \theta) \text{ ssssss} = \underset{\theta}{\operatorname{argmax}} \prod_{t=1}^N P(y_t; \theta)$$

- בעיות:
- יכולים להיות המון פרמטרים ב $\theta$
  - ברוב המודלים "המעשיים" - אין פתרון אנליטי, ולכן נדרש אלגוריתם חיפוש

קיים אלגוריתם איטרטיבי שנקרא  $EM$  (Expectation Maximization) שמחפש בכל איטרציה ערך חדש ל $\theta$  (אומדן  $\theta$ ), כך שמובטח שבכל איטרציה ערך הנראות  $P(y; \hat{\theta})$  יעלה, עד התכנסות. לכן מובטחת התכנסות לנקודת מקסימום, ייתכן מקסימום לוקאלי.

### אלגוריתם $EM$ למודל עירוב היסטוגרמות

אתחול: ערך  $\theta$  כלשהו (רנדומית, יוניפורמית, או "ניחוש מושכל"<sup>1</sup>)

נחזור איטרטיבית:

1. שלב  $E$ : נחשב לכל מסמך  $y_t$  את  $w_{ti} = P(x_i = x_t | y_t; \theta)$  - ההסתברות שהמסמך שייך לקטגוריה  $x_i$ . E=Expectation
2. שלב  $M$ : M=Maximization

$$P(x_i) = \frac{\sum_{t=1}^N w_{ti}}{\sum_{j=1}^{|X|} \sum_{t=1}^N w_{tj}} = \frac{\sum_{t=1}^N w_{ti}}{N}$$

אינטואיטיבית: תוחלת מניית מספר מסמכי  $x_i$  מנורמל בסכום התוחלות לכל ערכי  $X$  ( $N=|X|$ )

$$P(w_k | x_i) = \frac{\sum_{t=1}^N n_{tk} \cdot w_{ti}}{\sum_{\ell=1}^V \sum_{t=1}^N n_{t\ell} \cdot w_{ti}} = \frac{\sum_{t=1}^N n_{tk} \cdot w_{ti}}{\sum_{t=1}^N w_{ti} \cdot n_t}$$

- כאשר:
- $n_{tk}$  - שכיחות מילה  $w_k$  ב $y_t$
  - $n_t$  - אורך מסמך  $y_t$

3. עזירה: כאשר  $P(y; \theta)$  לא עולה.

לביצוע תנאי העזירה:

<sup>1</sup>למשל - לאתחל את ההסתברות של מילה בכל הקטגוריות לפי ההסתברות שלה בלי חלוקה לקטגוריות

- נחשב לכל איטרציה את  $P(y; \theta)$  (הערת debug: נבדוק שגדל מאיטרציה קודמת)
- נעצור אם שווה (פרקטית הבדל קטן) מאיטרציה קודמת (או איטרציות קודמות)

## אי שוויון Jensen

זהו אי שוויון שמתקיים על פונקציות קמורות

### הגדרה - פונקציה קמורה<sup>2</sup>

פונקציה  $f(x)$  נקראת קמורה (Convex) אם לכל  $x_1, x_2$  בתחום, ולכל  $\alpha \in [0, 1]$  מתקיים:

$$f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha \cdot f(x_1) + (1 - \alpha) \cdot f(x_2)$$

### בכיוון ההפוך

פונקציה  $f(x)$  נקראת קעורה (Concave) אם לכל  $x_1, x_2$  בתחום, ולכל  $\alpha \in [0, 1]$  מתקיים:

$$f(\alpha x_1 + (1 - \alpha)x_2) \geq \alpha \cdot f(x_1) + (1 - \alpha) \cdot f(x_2)$$

## הרחבה לאוסף של נקודות

למספר כלשהו של נקודות  $x_1, \dots, x_n$  בתחום, ועבור  $\alpha_1, \dots, \alpha_n \in [0, 1]$  כך  $\sum_{i=1}^n \alpha_i = 1$ , יתקיים בפונקציה קמורה:

$$f\left(\sum_{i=1}^n \alpha_i x_i\right) \leq \sum_{i=1}^n \alpha_i \cdot f(x_i)$$

## אינטרפרטציה הסתברותית

$x_i$  ערכי משתנה מקרי דיסקרטי  $X$

$\alpha_i$  הסתברות  $p(x_i)$

נקבל עבור פונקציה קמורה:

$$f\left(\sum_{i=1}^n p(x_i) \cdot x_i\right) \leq \sum_{i=1}^n p(x_i) \cdot f(x_i)$$

$$f(E[x]) \leq E[f(x)]$$

במילים: אם  $f$  פונקציה קמורה, ונפעיל אותה על תוחלת, נקבל ערך יותר קטן מאשר אם נפעיל תוחלת על הפונקציה.

## אנטרופיה יחסית (Relative Entropy)

נקרא גם Kullback-Leibler Divergence

מטרה: מדד לסטיה בין שתי התפלגויות

### הגדרה

נתונות שתי התפלגויות דיסקרטיות  $p, q$  מעל  $n$  ערכים  $p = p_1, \dots, p_n$   $q = q_1, \dots, q_n$ . נגדיר:

$$D_{KL}(p||q) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i}$$

### משמעות בתורת האינפורמציה

כמות אובדן המידע (בביטים) כשמדלים את  $p$  ע"י  $q$ .

### מקרי קצה

עבור  $p = q$  -  $D(p||q) = 0$   
אם קיים  $i$  כך ש  $q_i = 0$ , אזי  $D_{KL}$  לא מוגדר (" $\infty$ ")

### טענה

$$D(p||q) \geq 0$$

### הוכחה

$$D(p||q) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i} \leq \log \sum_i p_i \cdot \frac{q_i}{p_i} = \log_1 = 0$$

log is convex  
Jensen's inequality



## הצורה הכללית של אלגוריתם EM

המאמר המקורי משנת 1977:

Maximum Likelihood from Incomplete Data via the EM Algorithm  
Dempster, Laird, Rubin

נלמד גרסא של הפיתוח:

Neal & Hinton, 98: A View of the EM Algorithm

המטרה: קירוב  $\theta_{ML}$ , ע"י מציאת  $\hat{\theta}$ , עבור משתנים חבויים כשאין פתרון אנליטי, ע"י אלגוריתם איטרטיבי.

מניחים התפלגות  $P(X, Y; \theta)$ , חבוי  $X$ , גלוי  $Y$ ,  
מחפשים:

$$\hat{\theta}_{ML} = \operatorname{argmax}_{\theta} \log p(y; \theta) = \operatorname{argmax}_{\theta} \log \sum_{x \in X} p(x, y; \theta)$$

בדרך כלל אין פתרון אנליטי(ללוג של סכום) - נפתח שיטה איטרטיבית שבה בכל איטרציה ערך  $p(y; \theta)$  יעלה.