

## התפלגות משותפת של מ"מ $X, Y$ - $p(X, Y)$

### התפלגות שולית

$$p_X(x) = \sum_{y \in Y} p(x, y)$$

$$p_Y(y) = \sum_{x \in X} p(x, y)$$

טריוויאלית:

$$\sum_x p_X(x) = 1$$

### תוחלת של פונקציה מעל התפלגות משותפת

$$E[g(x, y)] = \sum_{x, y} g(x, y) \cdot p(x, y)$$

### לדוגמה

תוחלת של סכום ערכי משתנים מקריים בהתפלגות משותפת שווה לסכום התוחלות של שני המשתנים (ע"פ ההתפלגות השולית).

### הוכחה

$$\begin{aligned} E[X + Y] &= \sum_x \sum_y (x + y) \cdot p(x, y) = \\ &= \sum_x \sum_y x \cdot p(x, y) + \sum_x \sum_y y \cdot p(x, y) = \\ &= \sum_x x \cdot p(x) + \sum_y y \cdot p(y) = E[X] + E[Y] \end{aligned}$$

### משתנה מקרי בלתי תלוי

מ"מ  $X$  ו  $Y$  נקראים בלתי תלויים (ב"ת) אם לכל  $x \in X$  ו  $y \in Y$  מתקיים:

$$p(x, y) = p_X(x) p_Y(y)$$

## התפלגות מותנית של מ"מ $p_{X|Y}(x|y)$

פונקציית הסתברות שמגדירה

$$p_{X|Y}(x|y) = P(\{X = x\}|\{Y = y\}) = \frac{P(\{X = x, Y = y\})}{P(\{Y = y\})} = \frac{p(x, y)}{p(y)}$$

מתקיים לכל  $y$  מסויים:

$$\sum_x p(x|y) = 1$$

## אמדון (Estimation)

### הקדמה - שימוש במודלים הסתברותיים

נגדיר מודל הסתברותי לתופעה שבה מתעניינים, למטרות שונות:

- הסבר - פענוח, סיווג. לדוגמה - להחליט באיזה נושא הכתבה לפי המילים שיש בה
- חיזוי - מזג אוויר, בורסה
- יצירה - יצירת דיבור, תרגום

נגדיר אוסף מ"מ ומהם הפרמטרים שלפיהם נקבעים ערכי המשתנים.

לדוגמה: מטבע - כגון הסתברות המילה "ילד" בטקסט - נמדל כבינום.

בד"כ נסתכל על ההתנהגות "הגנרטיבית" של המודל שמייצרת את התצפיות בניסוי

לדוגמה: מודל הסתברות מילה "ילד" כבינום.

תהליך גנרטיבי אפשרי: מעבר על כל מקום בטקסט, ועבורו מגרילים בהסתברות  $p$  האם תופיע המילה "ילד" או מילה אחרת.

נשים  $\heartsuit$ : זהו מודל מאוד פשטני, ויש מודלים שממדלים יותר טוב - למשל מסתכלים על ההקשר של המשפט. אבל בד"כ נרצה להגביל את כמות המשתנים כדי לפשט את המודל, ולכן המודלים שלנו יהיו מקורבים.

### סימון מקובל

$\theta$  אוסף הערכים להסתברויות שמוגדרות במודל - הפרמטרים של המודל

לדוגמה - במשתנה בינומי  $\theta = \{p\}$

### שערוך מודל

תהליך אומדן ערכי הסתברויות שבו  $\theta$ . יתבצע ע"י דגימה סטטיסטית.

למשל: אומדן  $p$  למטבע: נתיל 100 הטלות ונניח שקיבלנו 70 הצלחות  $\Leftarrow$  נשערך  $p = 0.7$ .  
למה?

## אומדן נראות מקסימלית (Maximum Likelihood Estimation)

### נראות (Likelihood)

אינטואיציה: בהנתן שאני יודע מה ערכי הפרמטרים, מהי ההסתברות לתצפית מסויימת?  
עבור תצפית מסויימת, הנראות של התצפית היא ההסתברות לקבל אותה על פי ערכי פרמטרים נתונים של המודל.

$$\text{נסמן: } p \left( \begin{matrix} \text{observation} \\ \widehat{O} \end{matrix} ; \theta \right)$$

לדוגמה: בבינום:  $p(70, 100; p)$  (70 הצלחות מתוך 100 נסיונות עבור הפרמטר  $p$ )  
הפונקציה הזו היא פונקציה של  $p$  - לכל  $p$  אפשרי היא קובעת את ההסתברות לקבלת התצפית עבור ערך זה של  $p$

### הרציונאל אומדן נראות מקסימלית

מכיוון שאנחנו יודעים את התצפית ורוצים לחשב לפיה את הפרמטרים, נרצה למצוא  $\theta$  כך ש  $p(O, \theta)$  מקסימלי

### אומדן נראות מקסימלי

נבחר כאומדן נראות מקסימלי (MLE):

$$p_{MLE}(\langle 70, 100 \rangle) = \operatorname{argmax}_p p(70, 100; p) = 0.7$$

### באופן כללי

$$\theta_{ML} \left( \begin{matrix} \text{given observation} \\ \widehat{O} \end{matrix} \right) = \operatorname{argmax}_{\theta} p \left( \begin{matrix} \text{constant parameter} \\ \widehat{O} ; \widehat{\theta} \end{matrix} \right)$$

$$p_{MLE} \left( \left\langle \begin{matrix} \text{attempts} \\ \widehat{n} \end{matrix}, \begin{matrix} \text{successes} \\ \widehat{k} \end{matrix} \right\rangle \right) = \frac{k}{n}$$

עבור  $n, k$  נתונים בתצפית (קבועים):  
פונקציית הנראות:  $p(k, n; p) = \binom{n}{k} p^k (1-p)^{n-k}$   
אנו רוצים למצוא את ערך  $p$  שימקסם את פונקציית הנראות: לפונקציית הבינום ניתן למצוא פיתרון אנליטי ע"י גזירה.

יהיה נוח יותר לגזור את  $\log$  של פונקציית הנראות - ובגלל מונוטוניות  $\log$ ,  $p$  שימקסם את  $\log$  ממקסם את הפונקציה המקורית. נסמן (likelihood)  $L = \log$

$$L(p) = \log p(k, n; p) = \log \left( \binom{n}{k} p^k (1-p)^{n-k} \right) = \log \binom{n}{k} + k \log p + (n-k) \log (1-p)$$

נגזור (תזכורת  $(\log x)' = \frac{1}{x}$ ) ונשווה לאפס:

$$\frac{dL(p)}{dp} = \frac{k}{p} - \frac{n-k}{1-p} = 0$$

$$k - \cancel{kp} = np - \cancel{np} \implies p = \frac{k}{n}$$

הערה: כדי להוכיח שזו נקודת מקסימום, צריך להראות שהפונקציה קעורה ( $\cap$ ): נגזרת שנייה שלילית בכל התחום של  $p$ .

## ההצדקה ל-MLE

באיזה מובן MLE הוא הנכון?

אינטואיציה: נניח שיש לנו מטבע שהפרמטר האמיתי שלו הוא 0.7, ואנו רוצים למצוא את זה. אם נטיל אותו  $n = 100$  פעמים ונקבל נגיד  $k = 68$ . במקרה כזה  $p_{MLE} = 0.68$ . אם נגדיל ל  $n = 10000$  נקבל אולי  $p_{MLE} = 0.705$ . אפשר להוכיח שככל שנגדיל את  $n$ ,  $p_{MLE}$  יתכנס לערך האמיתי  $p$  - זהו אומדן חסר הטיה<sup>2</sup>

ניתן להוכיח: עבור תצפית שנוצרות על ידי הפרמטרים של המודל(האמיתיים - אלו שאותם מנסים לשערך) מתקיים שאומדן MLE מתכנס לערכי הפרמטרים עם הגדלת המדגם(שואף ל  $\infty$ ).

זה נקרא: אומדן עקבי אסימפטוטית Asymptotically consistent

<sup>1</sup>כאשר מסתכלים מלמטה  $\cap$  זה קעור ו  $\cup$  זה קמור  
<sup>2</sup>אומדן חסר הטיה - אומדן שככל שמגדילים את גודל המדגם מתכנס לערך האמיתי