

## התפלגות מולטינומית Multinomial

משתנה  $X$  שמקבל  $m$  ערכים שונים  $x_1, \dots, x_i, \dots, x_m$ , כל ערך  $x_i$  בהסתברות  $p_i$ ,  $\sum_{i=1}^m p_i = 1$ .

**נוסחת הסתברות למולטינום:**

עבור  $n$  דגימות ממולטינום, ההסתברות לקבלת  $k_i$  דגימות מכל ערך  $x_i$  נקבעת לפי הנוסחה:

$$P_n(k_1, k_2, \dots, k_m) = \frac{n!}{k_1! \dots k_m!} \cdot p_1^{k_1} \dots p_m^{k_m}$$

נתעניין בכל פעם בערך יחיד של המשתנה, ניתן להסתכל עליו כמשתנה בינומי כשהערך המבוקש נחשב הצלחה, אחרת כישלון.

**אומדן ML:**

$$p_i = p(x_i) = \frac{k_i}{n}$$

לפי  $n$  דגימות

**תוחלת מספר הפעמים לקבלת ערך  $x_i$  ב  $n$  דגימות:**

כמו בבינום:  $n \cdot p_i$

## מודל שפה - Language Model

**התופעה שרוצים למדל:**

יצירה של רצפים של סימנים מתוך אוסף דיסקרטי של סימנים אפשריים.

**מבט גנרטיבי:**

יש מקור שמייצר את רצף הסימנים לפי מודל הסתברותי כלשהו.

**מטרת מודל שפה הסתברותי:**

בהינתן רצף סימנים, לחשב את ההסתברות ליצירת הרצף

**לדוגמה:**

במערכת לזיהוי דיבור, נרצה מודל שפה שיידע לאמוד את ההסתברות של כל משפט אפשרי, ובהתאם המערכת לעדיף לייצר משפטים סבירים יותר.

## פיתוח מודל שפה הסתברותי

בהינתן דגימה של סדרת סימנים בשפה:  $s = w_1, \dots, w_n$ , נרצה למדל את  $P(w_1, \dots, w_n)$  צעד ראשון:

$$P(w_1, \dots, w_n) = P(\text{length}(s) = n) \cdot p(s | \text{length}(s) = n)$$

$$\sum_{n=1}^{\infty} P(\text{length}(s) = n) = 1 \quad \heartsuit \text{ נשים}$$

עבור  $n$  מקובע:

$$\sum_{\substack{w_1, \dots, w_n \\ \forall_i w_i \in W}} P(w_1, \dots, w_n | \text{length} = n) = 1$$

(כאשר  $W$  - סט כל המילים האפשריות)

### מודל הסתברות הסדרה - נניח $|s| = n$

נשים לב שמספר המשפטים האפשריים מאוד גדול ( $|W|^n$ ) - הרבה יותר גדול ממספר הדגימות שיש לנו. לכן נרצה לפרק את המשפט.

$$P(w_1, \dots, w_n) = P(w_1) \cdot P(w_2 | w_1) \cdot P(w_3 | w_1, w_2) \cdots P(w_n | w_1^{n-1})$$

כדי לקבל מודל שניתן לשערך את ההסתברויות שלו, נניח הנחות אי תלות. למשל - הסתברויות המילים בסדרה אינן תלויות אחת בשנייה:

$$\text{assuming independence} = P(w_1) \cdot P(w_2) \cdots P(w_n) = \prod_{i=1}^n P(w_i)$$

קיבלנו מודל מולטינומי, עם  $|W|$  ערכים אפשריים.

המודל הגנרטיבי: בכל מקום  $i$ , מגרילים מילה  $w_i$  בהסתברות  $P(w_i)$ :  $P_{ML}(w) = \frac{\text{freq}(w)}{N}$  (כאשר  $N$  - גודל המדגם)

## דוגמאות לשימושים

- סיווג מאמרים - למשל אם מקבלים מסמך  $d$ , וידוע לנו ההסתברות של מילים  $w \in W$  להימצא במאמר ספורט  $P^S(w)$  ומה ההסתברות שלה להימצא במאמר משפטי  $P^L(w)$ , ואז אם  $P^L(d) > P^S(d)$  נסווג את המאמר בתור מאמר משפטי ולא בתור מאמר ספורט.

- זיהוי דיבור - אם יש שתי היפותזות לגבי מה שהמשתמש אמר, נעדיף את היפותזה א' על פני ב' אם  $P^*(A) > P^*(B)$

המודל המולטינומי הוא לא האפשרות היחידה. נראה כעת מודל אחר(נראה אותו תחת הדוגמה של סיווג מסמכים):

## דוגמה למודל עבור קבוצות(סט) מילים

נשים ♡: בקבוצה אין חזרות ואין חשיבות לסדר. במודל המולטינומי, אמנם כאשר מניחים אי תלות אין חשיבות לסדר - אבל עדיין יש חשיבות לחזרות.

## Multiple Bernouli

כדי למדל קבוצת סימנים שנצפתה(למשל - קבוצת המילים שהופיעה במסמך לצורך סיווג טקסטים), נתייחס ליצירת הקבוצה כדגימה ממספר משתני ברנולי: לכל מילה אפשרית בשפה  $w \in W$  נגדיר:

$P(w)$  ההסתברות שהמילה תופיע במסמך אקראי  
ובהתאם -  $1 - P(w)$  - ההסתברות שלא תופיע

תהליך היצירה: לכל מילה במילון, נגדיל לפי הסתברות  $P(w)$  באם לכלול אותה במסמך.  
נסמן  $d$  מסמך אקראי:  $d \subseteq W$

$$P(d) = \prod_{w \in d} P(w) \cdot \prod_{w \notin d} (1 - p(w))$$

נשים ♡: אפשר להסתכל על תת קבוצה  $d$  כוקטור בינרי באורך  $|W|$

אומדן  $P(w)$ :

$$P(w) = \frac{\text{number of documents containing } w}{\text{number of documents in the sampling}}$$

נשווה לעומת המודל המולטינומי, שבו

$$P(w) = \frac{\text{number of occurrences of } w \text{ in all the texts}}{\text{number of occurrences of all the words in all the texts}}$$

## ראוי לציין

בדרך כלל כשרוצים למדל שפה טבעית, עדיף להשתמש במודל מולטינומי כי יש חשיבות לשכיחות של המילים.

## הקדמה לשיעור הבא - מידול רצפי סימנים ע"י מודל n-gram

אינטואיציה: מניחים שההסתברות של מילה מושפעת מהמילים לפניה - אבל לא יותר מדי, מטעמי גודל מדגם ומטעמי חישוביות.

טעם נוסף זה שככל שהולכים יותר אחורה מאבדים הקשר - אבל בדרך כלל מגיעים למגבלה הטכנית הרבה לפני שזה קורה.

המודל המולטינומי:

$$P(w_1, \dots, w_n) = P(w_1) P(w_2|w_1) \dots P(w_n|w_1, \dots, w_{n-1})$$

ולאחר הנחות אי תלות מקבלים מודל יוניגרם:

$$P(w_1) P(w_2) \dots P(w_n)$$

מודל ביגרם:

$$P(w_1) P(w_2|w_1) P(w_3|w_2) \dots P(w_n|w_{n-1})$$

מודל טריגרם:

$$P(w_1) P(w_2|w_1) P(w_3|w_1, w_2) \dots P(w_n|w_{n-2}, w_{n-1})$$

$P(w_i w_1, \dots, w_{i-1}) = P(w_i)$	יוניגרם	הנחות:
$P(w_i w_1, \dots, w_{i-1}) = P(w_i w_{i-1})$	ביגרם	
$P(w_i w_1, \dots, w_{i-1}) = P(w_i w_{i-2}, w_{i-1})$	טריגרם	
$P(w_i w_1, \dots, w_{i-1}) = P(w_i w_{i-n+1}, \dots, w_{i-1})$	n-גרם	