

החלקת Held Out

שכיחות באימון r

$$t_r = \sum_{x: C^T(x)=r} C^H(x)$$

$$p_{HO}(x|C^T(x)=r) = \frac{t_r}{N_r \cdot |S^H|}$$

N_0 מספר ערכי X שלא נצפו ב S^T

נשים \heartsuit שיש כאן הנחה מובלעת שגודל X ידוע:

הנחה: $|X|$ ידוע.

פרקטית במידע ולא ידוע, צריך להניח את $|X|$, וזה הופך להיות פרמטר של השיטה

נשים \heartsuit : הנוסחה לא מחייבת $|S^H| = |S^T|$.

$|S^T|$ משמש לאומדן הסתברות משמש לאומדן הסתברות של ערכי X ספציפיים

$|S^H|$ משמש לאומדן הסתברות של מחלקות שכיחות (ערכי r אפשריים)

במקרים שבהם יש יותר ערכי X מאשר מחלקות שכיחות נעדיף S^T גדול יותר

נראה שסכום האומדנים מסתכם ל:1:

$$\sum_{x \in X} p_{HO}(x) = \sum_{r=0}^{\infty} \left(\frac{t_r}{N_r |S^H|} \cdot N_r \right) = \frac{\sum_{r=0}^{\infty} t_r}{|S^H|} = \frac{|S^H|}{|S^H|} = 1$$

ביצוע הפחתה (discount) רק לערכי r נמוכים יחסית (בכל שיטת הפחתה)

$(n_r \equiv N_r)$

מוטיבציה: • הפחתה חשובה ל r נמוכים

• ב r גבוהים ייתכנו אנומליות בהחלקה

נבצע החלקה רק ל $r \leq R$ עבור R גדול כלשהו. כדי שסכום האומדנים יסתכם ל1, נעשה זאת על ידי כך שנחלק לערכים עם $r = 0$ את אותה מסת הסתברות שהתפנתה מההחלקה. נרצה שיתקיים:

$$1 = n_0 \cdot p(x|C^T(x)=0) + \sum_{r=1}^R n_r \cdot p_d(x|C^T(x)=r) + \sum_{r=R+1}^{\infty} n_r \cdot p_{MLE}(x|C(x)=r)$$

↓

$$p_d(x|C^T(x)=0) = \frac{1}{n_0} \left[1 - \sum_{r=1}^R n_r \cdot p_d(r) - \sum_{r=R+1}^{\infty} n_r \cdot p_{MLE}(r) \right]$$

נשים ♡: שיטת תיקון זו מניחה ש $\sum_{r=1}^R n_r p_d(r) < \sum_{r=1}^R n_r p_{MLE}(r)$. כלומר - P_d ש P_d אך מבצע בפועל הפחתה של האומדנים ל $r = 1, \dots, R$. (אחרת נקבל אומדן שלילי ל $P_d(r=0)$).

שיטת החלקת Back-Off

מוטיבציה: אומדן בהסתברות מותנית ל n-gram. למשל: ביגרם: $p(w'|w)$.
ניזכר - זו התפלגות מותנית נפרדת לכל w מותנה: $\sum_{w'} p(w'|w) = 1$.
האומדן דורש החלקה, בפרט לא נרצה להשתמש ב $p_{MLE}(w'|w) = 0$ למילים w' שלא נצפו אחרי w .
אם נשתמש בהחלקה רגילה (כגון Lid, H.O.), כל המילים w' כך ש $\text{freq}(w, w') = 0$ $p_{MLE}(w'|w) = 0$ יקבלו את אותה הסתברות מותנית ב w .
אבל: נסתכל על w', w'' כך ש

$$p_{MLE}(w'|w) = p_{MLE}(w''|w) = 0$$

$$p(w') > p(w'')$$

נרצה שייתקיים:

$$p_d(w'|w) > p_d(w''|w)$$

זו מטרת שיטת ה B.O. - נחלק את המסה עבור מילים שלא נצפו אחרי w באימון באופן פרופורציונלי לשכיחות (היוניגרם) שלהם:

$$p_B(w'|w) = \begin{cases} p_d(w'|w) & C(w, w') > 0 \\ \alpha(w) \cdot p_d(w') & \text{otherwise} \end{cases}$$

כאשר: P_d שיטת החלקה הבסיסית שבה משתמשים
 C המונה במדגם האימון
 $\alpha(w)$ מקדם נרמול שיבטיח סכום 1 להסתברויות יקצה ל w' במקרה השני ($C(w, w') = 0$) את המסה שהתפנתה במקרה הראשון ($C(w, w') > 0$)
חישוב $\alpha(w)$: נסמן $\beta(w)$ - מסת ההסתברות שהתפנתה ב (1) ע"י החלקה:

$$\beta(w) = 1 - \sum_{w': C(w, w') > 0} p_d(w'|w)$$

צריך שייתקיים: β שווה למסה שנקצה במקרה השני:

$$\beta(w) = \sum_{w': C(w, w') = 0} \alpha(w) \cdot p_d(w')$$

$$\Rightarrow \alpha(w) = \frac{\beta(w)}{\sum_{w': C(w, w') = 0} p_d(w')} = \frac{1 - \sum_{w': C(w, w') > 0} p_d(w'|w)}{1 - \sum_{w': C(w, w') > 0} p_d(w')}$$

נשים לב שעוברים מ $\sum_{w': C(w, w') = 0} p_d(w')$ ל $1 - \sum_{w': C(w, w') > 0} p_d(w'|w)$ בגלל שחישובית הרבה יותר קל לעבור על המילים שכן הופיעו אחרי w מאשר על המילים שלא הופיעו אחרי w
אם $C(w) = 0$ אזי $\alpha(w) = 1$, וההסתברות $p(w'|w)$ מנוונת ל $p_d(w')$.