

$$H = - \sum_{\substack{i \in I_1 \\ j \in J_1}} p'(i|j) \cdot \log p'(j|i) - \sum_{\substack{i \in I_2 \\ j \in J_2}} p'(i|j) \cdot \log p'(j|i) - \sum_{i \in I_1, j \in J_2} p'(i|j) \cdot \log p'(i|j) \\ - \sum_{i \in I_2, j \in J_1} p'(i|j) \cdot \log p'(i|j)$$

dvojice z odlišných textů

Sumu lze zjednodušit, a to tak, že jedním dvojice slova z odlišných textů se může vyskytovat na rozhnutí. Označme tyto slova $x_i \in T_1, x_j \in T_2$

$$= - \sum_{\substack{i \in I_1 \\ j \in J_1}} p'(i|j) \cdot \log p'(j|i) - \sum_{\substack{i \in I_2 \\ j \in J_2}} p'(i|j) \cdot \log p'(j|i) - p(x_i, x_j) \cdot \log(p(x_j|x_i))$$

$$p'(i|j) = \frac{c(i,j)}{\# \text{dk. } T_1 + \# \text{dk. } T_2 + 1} \Rightarrow p'(i|j) \leq p(i,j)$$

$$p'(j|i) = p'(j,i) / p'(i) = \frac{c(j,i)}{\# \text{dk. } T_1 + \# \text{dk. } T_2 + 1} \cdot \frac{\# \text{slov. } T_1 + \# \text{slov. } T_2}{c(i)}$$

$$\# \text{slov} - 1 = \# \text{dvojice} \Rightarrow \# \text{slov} \sim \# \text{dvojice} \Rightarrow p'(j|i) \doteq \frac{c(j,i)}{c(i)}$$

↳ uvážejte jen vyskytující se dvojice

Na rozhnutí se mohou stát následující situace

($x_i :=$ poslední slovo v $T_1, x_j :=$ první slovo v T_2)

- x_i se nachází pouze na konci T_1 : $\forall i \in I_1: i \neq x_i$

pak výpočet $-\sum_{\substack{i \in I_1 \\ j \in J_1}} p'(i|j) \cdot \log p'(j|i)$ není nijak ovlivněn,

dále $p(x_j|x_i) = 1 \Rightarrow \log(p(x_j|x_i)) = 0 \Rightarrow$ zelená část se nemění, žlutá část bude 0.

- x_i se nachází i jinde v textu T_1 : $\exists i \in I_1: i = x_i$

pak ve výpočtu $-\sum_{\substack{i \in I_1 \\ j \in J_1}} p'(i|j) \cdot \log p'(j|i)$ klesne hodnota $p'(j|i)$ pro $i = x_i$,

tedy $\log(p(j|i))$ se zvýší, protože i hodnota entropie.

dále $p(x_j|x_i) < 1 \Rightarrow \log(p(x_j|x_i)) > 0 \Rightarrow$ zelená část se zvýší, žlutá část bude mít $\neq 0$ hodnotu

$$\Rightarrow = - \sum_{\substack{i \in I_1 \\ j \in J_1}} p'(i|j) \cdot \log p(j|i) - \sum_{\substack{i \in I_2 \\ j \in J_2}} p'(i|j) \cdot \log p(j|i) - p(x_i, x_j) \cdot \log(p(x_j|x_i))$$

$$p'_1(i|j) = \frac{\# \text{dv. } T_1}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot p_1(i|j)$$

$$p'_2(i|j) = \frac{\# \text{dv. } T_2}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot p_2(i|j)$$

$$= - \sum_{\substack{i \in I_1 \\ j \in J_1}} \frac{\# \text{dv. } T_1}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot p_1(i|j) \cdot \log p(j|i) - \sum_{\substack{i \in I_2 \\ j \in J_2}} \frac{\# \text{dv. } T_2}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot p_2(i|j) \cdot \log p(j|i) - p(x_j, x_i) \cdot \log(p(x_j|x_i))$$

$$= \frac{\# \text{dv. } T_1}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot E + \frac{\# \text{dv. } T_2}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \cdot E - p(x_j, x_i) \cdot \log(p(x_j|x_i))$$

$$= E \cdot \left(\frac{\# \text{dv. } T_1}{\# \text{dv. } T_1 + \# \text{dv. } T_2} + \frac{\# \text{dv. } T_2}{\# \text{dv. } T_1 + \# \text{dv. } T_2} \right) - p(x_j, x_i) \cdot \log(p(x_j|x_i))$$

V případě, že žlutá část = 0 (x_i se vyskytuje pouze na hoře T_1), je $H(T_1, T_2) = E$ a entropie se nezměnila.

V opačném případě v zelené části pro $i = x_i$:

$$p'(j|i) = \frac{c(j|i)}{c(i)+1} = \frac{c(j|i)}{c(i)} \cdot \frac{c(i)}{c(i)+1} = p(j|i) \cdot \frac{c(i)}{c(i)+1}$$

$$\text{tedy zelená část se zvýší o } \frac{\# \text{dv. v } T_1}{\# \text{dv. v } T_1 + \# \text{dv. v } T_2} \cdot p(i|j) \cdot \log\left(p(j|i) \cdot \frac{1}{c(i)+1}\right) = A$$

a do celkové sumy se přidá i žlutý člen

$$- p(x_j, x_i) \cdot \log(p(x_j|x_i)) = B$$

Proto pokud: $> 0 \Rightarrow$ entropie se zvýší

$(A - B) < 0 \Rightarrow$ entropie se sníží

Co bych měl ještě udělat:

Uniform prob. by měl váznout větší slova než

jen ten trénovací (protože: v reálné bde více neviděných slov)

Takže měo jako uniform prob:
$$\frac{1}{|T| + \alpha(|H - T \cap H|)}$$
 $\alpha \geq 1$

Takže α je potřeba si
vybrat z prstn.

T ... trénovací

H ... heldout

$H - T \cap H$ $\rightarrow$ počet "nových" slov, která
nebyly v trénovací datce.