

Другие сокращения: $u_1 u_2 \dots u_{n-1} w$

$$P(\underbrace{w | u_1 u_2 \dots u_{n-1}}_{n \text{ грам}}) = \frac{c(u_1 \dots u_{n-1} w)}{c(u_1 \dots u_{n-1})}$$

max likelihood

Корпус

3 гр. $\$$ $u_1 u_2 \dots u_{n-1} w$ - 0
 2 гр $\$$ $u_1 u_2 \dots u_{n-1} w$ - 10
 1 гр. $u_1 u_2 \dots u_{n-1} w$ - 20

Интерпретация для сокращения

$$P(w | u_1 u_2 \dots u_{n-1}) = \lambda_{n-1} \frac{c(u_1 \dots u_{n-1} w)}{c(u_1 \dots u_{n-1})} + \lambda_{n-2} \frac{c(u_2 \dots u_{n-1} w)}{c(u_2 \dots u_{n-1})} + \dots + \lambda_1 \frac{c(u_{n-1} w)}{c(u_{n-1})} + \lambda_0 \frac{c(w)}{\text{гласн. корпуса}}$$

λ можно подобрать, $\sum \lambda_i = 1$

Аналог Европы

$$P(w | u) = \lambda_1 \frac{c(uw)}{c(u)} + \lambda_0 \frac{c(w)}{N}$$

$$\sum_{w \in V} P(w | u) = 1$$

$$1 = \sum \left(\lambda_1 \frac{c(uw)}{c(u)} + \lambda_0 \frac{c(w)}{N} \right) = \lambda_1 \sum_w \frac{c(uw)}{c(u)} + \lambda_0 \sum_w \frac{c(w)}{N} = \lambda_1 + \lambda_0$$

$\lambda_1 + \lambda_0 = 1$
0.5 0.5
0.8 0.2
0.2 0.8

ногабар гиперпараметров.

Линейный вариант: Kneser-Ney

$$P(w | u) = \frac{c(uw) - \delta}{c(u)} + \frac{\delta}{|S_u|} \quad (1)$$

$\delta \left(\frac{c(u'w)}{c(u')} \right) \left(\frac{c(u''w)}{c(u'')} \right) \dots$
 все слова корпуса - все равно разное

u	$w^{(1)}$	$w^{(2)}$	$w^{(i)}$
0	0	0	0
		16.5	17.5
		200	200
		0.5/200	0.5/200

Большая вероятность встречается тем словам, которые часто встречаются в новых контекстах.
(у которых разное количество контекстов).

Пример: New York

1 вариант контекста слова York

big
small
gray
cat

100 вариантов контекста

+ много
в-т
 $P(\text{York} | \dots)$

+ много
в-т

$P(\text{cat} | \dots)$

(1) - кол-во разных контекстов, которые встречаются через w

(2) - кол-во ^{разных} слов, которые вообще встречаются в корпусе.

λ - гиперпараметр, ч-во $\sum_w P(w | \lambda) = 1$

Схема подбора гиперпараметров в машинном обучении

Хотим выбрать лучший model: ~~1. MLE ($P = \frac{c(w)}{c(w)}$)~~ - 0.

гиперпараметры: λ
разн / δ

2. Лаплас $\frac{c(w) + \lambda}{c(w) + \lambda \bar{w}}$

λ - разн

3. Интерполляция, подбор λ :

4. Кросс-Нес $\delta = ?$

корпус



training set

validation set

test set

Как генит:

all_sentences = [, ,]

shuffle - ф-ция из модуля random

word shuffle

- all-sentences [: 0.8 * len]
- all-sentences [0.8 * len : 0.9 * len]
- all-sentences [0.9 * len :]

Примеры подбора
 берем 1ое значение
 обучаем на training-set, оцениваем качество на validation-set
 берем 2ое значение ... (lambda, lambda=2)
 обучаем на training-set, оцениваем качество на validation-set
 берем 3ое значение (k=3, N=3, delta=0.1)
 обучаем на training-set, оцениваем качество на validation-set
 и т.д.

Подскажет тот, у кого качество на validation-set
 меньше всего.

Ответ: победившая модель + качество на test-set.

Оцениваем качество модели на корпусе (test-set)

P{текст} ↑ более - лучше

$$\begin{aligned}
 P\{\text{текст}\} &= P\{\text{word}_1\} \cdot P\{\text{word}_2\} \cdot \dots \cdot P\{\text{word}_N\} = \\
 &= P(w_1^{(1)} | <s>) \cdot P(w_2^{(1)} | w_1^{(1)}) \cdot \dots \cdot P(</s> | w_{n_1}^{(1)}) \cdot \\
 &P(w_1^{(2)} | <s>) \cdot P(w_2^{(2)} | w_1^{(2)}) \cdot \dots \cdot P(</s> | w_{n_2}^{(2)}) \cdot \dots
 \end{aligned}$$

↑ underflow

$$\log P\{\text{текст}\} = \log P(\cdot) + \log P(\cdot) + \dots + \log P(\cdot)$$

- нет underflow

Значит текст - вероятностная модель.

нашны белыт не P тукета, а сярэдняе
беласілінасць n-грамна.

$$\sqrt[n]{P(\text{тукета})}$$

$$\frac{1}{n} (\log P(\text{тукета}))$$

сярэдняе
n-грамна

$$E = \frac{\log P(w_1 | s) + \log P(l) + \dots + \log P(\langle \text{cls} \rangle | w_{n_i}^{(n)})}{n}$$

N = сярэдняе n-грамна.

$\log P(l)$ со

Perplexity = 2^E / сярэдняе беласілінасць адной n-грамна.

perplexity = 20 \Rightarrow сярэдняе беласілінасць = $1/20$

perplexity = 2000 \Rightarrow сярэдняе беласілінасць $1/2000$ \uparrow

perplexity гэтае дзеянне калі мы можам мець.