

Большие языковые модели, трансформеры, ChatGPT

Лукашевич Н.В., в.н.с. НИВЦ МГУ,
профессор ВМК МГУ

Тихомиров М.М., н.с. НИВЦ МГУ

Чернышев Д.И., аспирант ВМК

Диалог с ChatGPT в качестве эпиграфа

zo

сегодня я случайно села на свою любимую свигму и у нее отвалился хрюксер. что делать?



Если у вас отвалился хрюксер со свигмы, то следует немедленно обратиться за помощью к квалифицированному специалисту. Хрюксер является важным элементом свигмы, который обеспечивает ее стабильность и безопасность. Его отсутствие может привести к тому, что свигма станет нестабильной и небезопасной для использования.



Свяжитесь с магазином или производителем свигмы, чтобы узнать, как произвести ремонт хрюкзера или приобрести новый. В случае необходимости может потребоваться профессиональное установление хрюкзера, так что убедитесь, что у вас есть доступ к квалифицированному специалисту, который сможет выполнить эту работу. Пока хрюксер не будет заменен или установлен, не следует использовать свигм

План по дням

- 1. Нграммные языковые модели (Лукашевич Н.В., Тихомиров М.М.)
 - Основы нграммных языковых моделей
 - Исправление опечаток
 - Метод word2vec для векторизации слов
- 2. Автоматическое аннотирование (суммаризация текстов) (Чернышев Д.И.)
 - Векторные представления документов
 - Методы автоматического аннотирования
 - Архитектура типа трансформер
- 3. Информационный поиск (Тихомиров М.М.)
 - Классические модели
 - Модели на основе нейронных сетей
 - Методы тестирования
- 4. Модели семейства GPT (Тихомиров М.М., Лукашевич Н.В.)

N-граммные модели

Языковые статистические
модели

Языковые модели (language models)

- Определение вероятности предложений, последовательностей слов
- Как вероятна каждая последовательность?
 - $P(w_1, w_2, w_3, \dots, w_n)$
 - $P(w_5 | w_1, w_2, w_3, w_4)$
- Языковая модель – математическая модель, которая вычисляется вероятность последовательности слов или условную вероятность следования слова в контексте

Применения

- Распознавание речи
- Статистический машинный перевод
- Исправление опечаток
- Распознавание текстов

- Марковское предположение:
 - На появление слова влияет ограниченное количество предшествующих слов

N-граммы – последовательности n- слов

- Униграммы
- Биграммы
- Триграммы

- Как выбрать

Надежность vs. Точность предсказания

“large green _____”
tree? mountain? frog? car?

“swallowed the large green _____”
pill? broccoli?

Надежность vs. Точность предсказания

- Больше n : больше информации о контексте специфического примера (больше потенциальная точность предсказания)
- Меньше n : больше данных, лучше статистические оценки, больше надежности

Вероятность появления следующего слова

$$P(W_n | W_1, \dots, W_{n-1}) = P(W_1, \dots, W_n) / P(W_1, \dots, W_{n-1})$$

MLE (максимальное правдоподобие)

- $P_{mle}(W_1, \dots, W_n) = C(W_1, \dots, W_n) / N$
- $P_{mle}(W_n | W_1, \dots, W_{n-1}) = C(W_1, \dots, W_n) / C(W_1, \dots, W_{n-1})$
- $C()$ - частота появления подстроки

Для биграмм

$$P_{mle}(W_n | W_{n-1}) = C(W_{n-1}, W_n) / C(W_{n-1})$$

Пример

- Корпус
 - `<s> Он пошел в школу </s>`
 - `<s> Пошел он в школу</s>`
 - `<s> Он не любит мясо</s>`
- Вероятности по максимальному правдоподобию?:
 - Униграммы: он, пошел, мясо
 - Биграммы: $P(\text{он}|\text{пошел})$, $P(\text{пошел}|\text{он})$

Порождая Шекспира

- Порождение предложений из униграмм...
 - Every enter now severally so, let
 - Hill he late speaks; or! a more to leg less first you enter
- С биграммami...
 - What means, sir. I confess she? then all sorts, he is trim, captain.
 - Why dost stand forth thy canopy, forsooth; he is this palpable hit the King Henry.
- Триграммы
 - Sweet prince, Falstaff shall die.
 - This shall forbid it should be branded, if renown made it empty.

- Тетраграммы

- What! I will go seek the traitor Gloucester.

- Will you not tell me who I am?

- Это выглядит как Шекспир, поскольку это и есть Шекспир

- Т.е. как только мы увеличиваем величину N , точность модели растет, так как выбор следующего слова все более ограничен

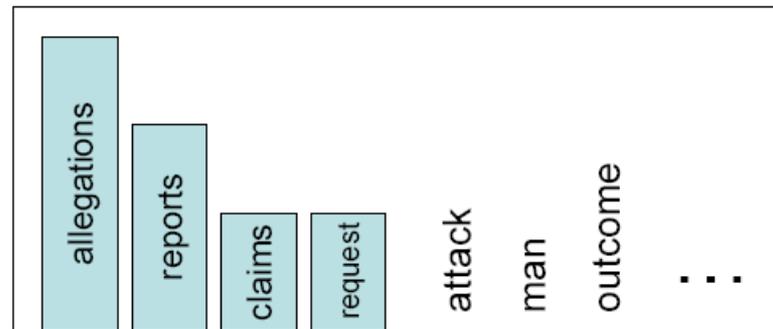
Проблема

- В тексте, который мы пытаемся предсказать, могут встретиться слова, которых не было
- Методы сглаживания (smoothing)

Smoothing is like Robin Hood: Steal from the rich and give to the poor (in probability mass)

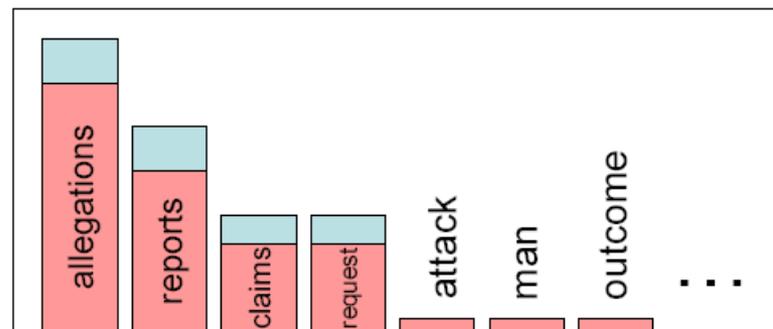
- We often want to make predictions from sparse statistics:

$P(w \mid \text{denied the})$
3 allegations
2 reports
1 claims
1 request
7 total



- Smoothing flattens spiky distributions so they generalize better

$P(w \mid \text{denied the})$
2.5 allegations
1.5 reports
0.5 claims
0.5 request
2 other
7 total



- Very important all over NLP, but easy to do badly!

Сглаживание Лапласа

- Для униграмм:

- Добавляем 1 к частоте каждого слова
- Нормализуем N (#tokens) + V (#types)
- Исходная вероятность униграммы

$$P(w_i) = \frac{c_i}{N}$$

- Новая вероятность униграммы

- Для биграмм

$$P_{LP}(w_i) = \frac{c_i + 1}{N + V}$$

- исходная

$$P(w_n | w_{n-1}) = \frac{c(w_n, w_{n-1})}{c(w_{n-1})}$$

- новая

$$P(w_n | w_{n-1}) = \frac{c(w_{n-1}, w_n) + 1}{c(w_{n-1}) + V}$$

Статистические оценки

Пример:

Корпус: пять романов Джен Остин

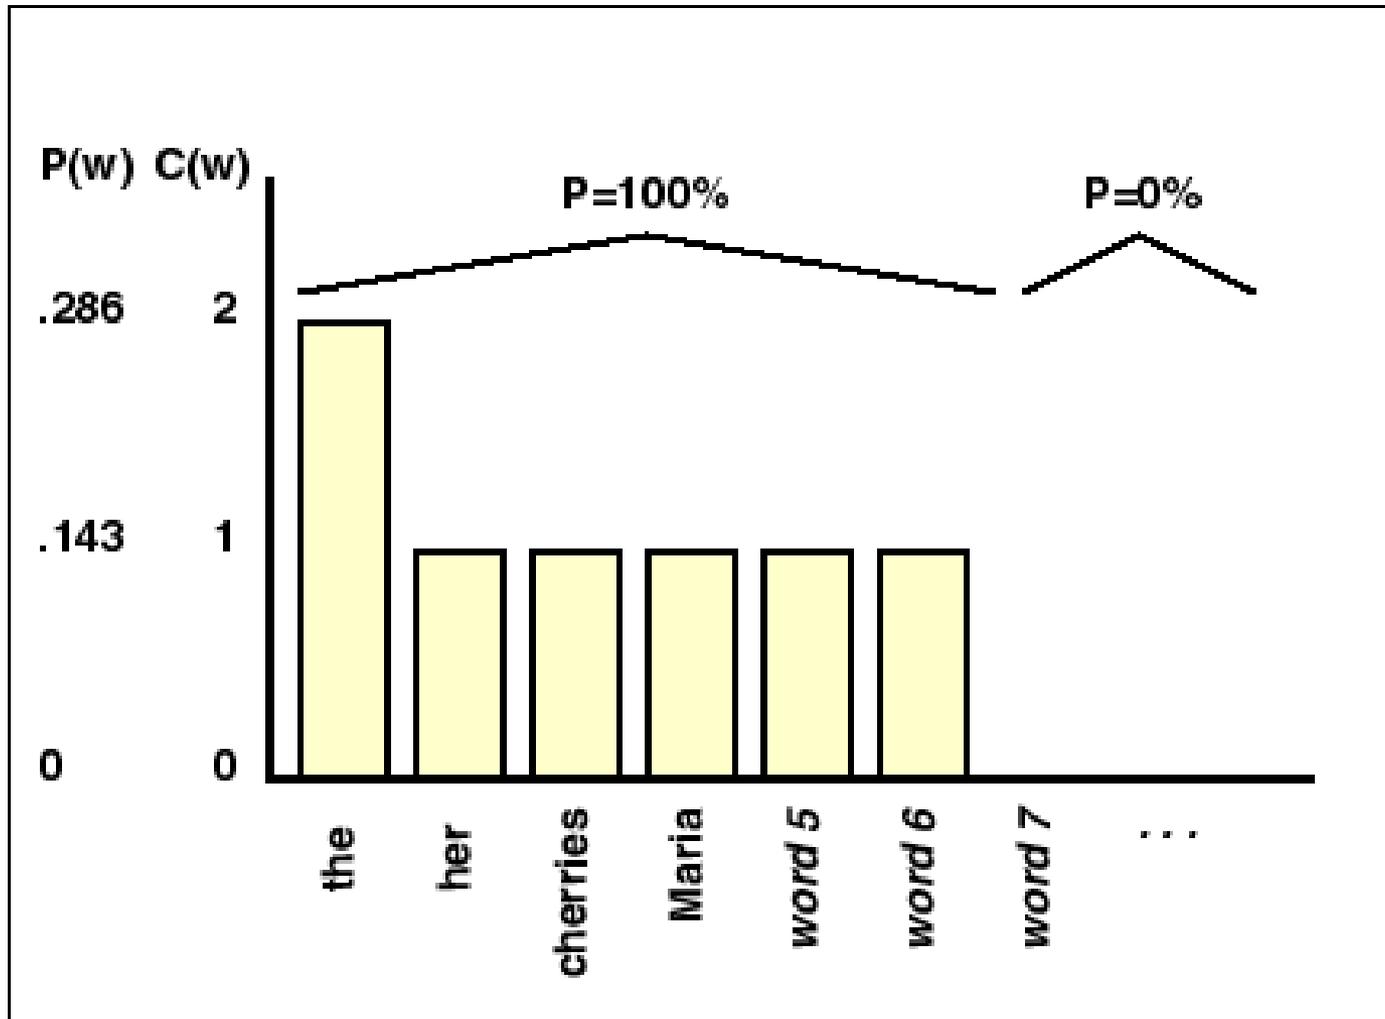
$N = 617,091$ слов

$V = 14,585$ уникальных слов

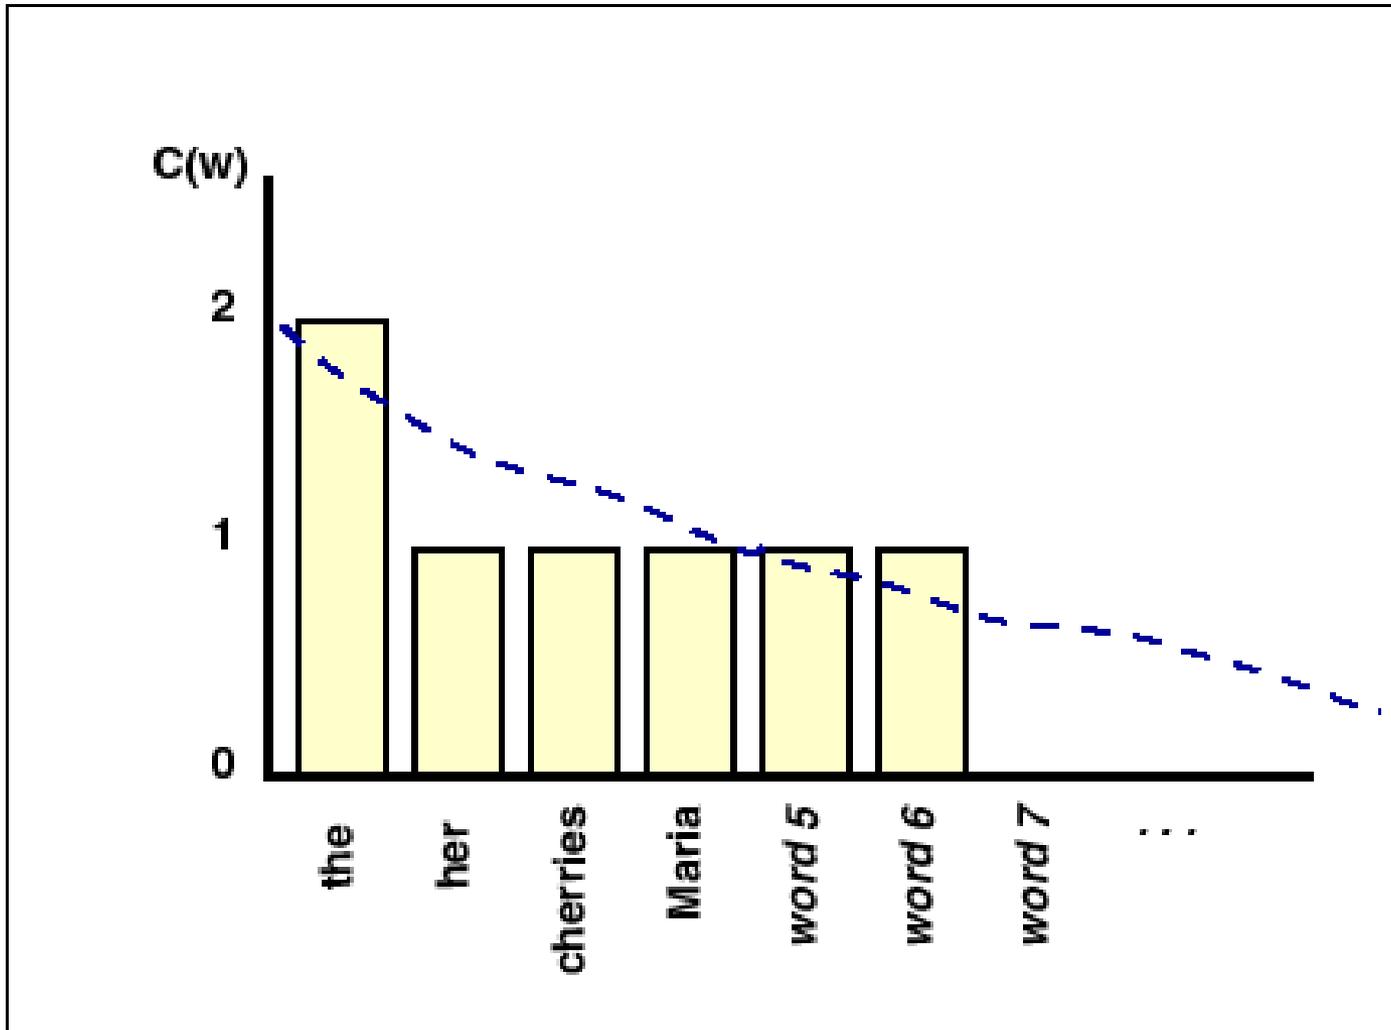
Задача: предсказать следующее слово
триграммы “inferior to _____”

from test data, *Persuasion*: “[In person, she was] inferior to *both* [sisters.]”

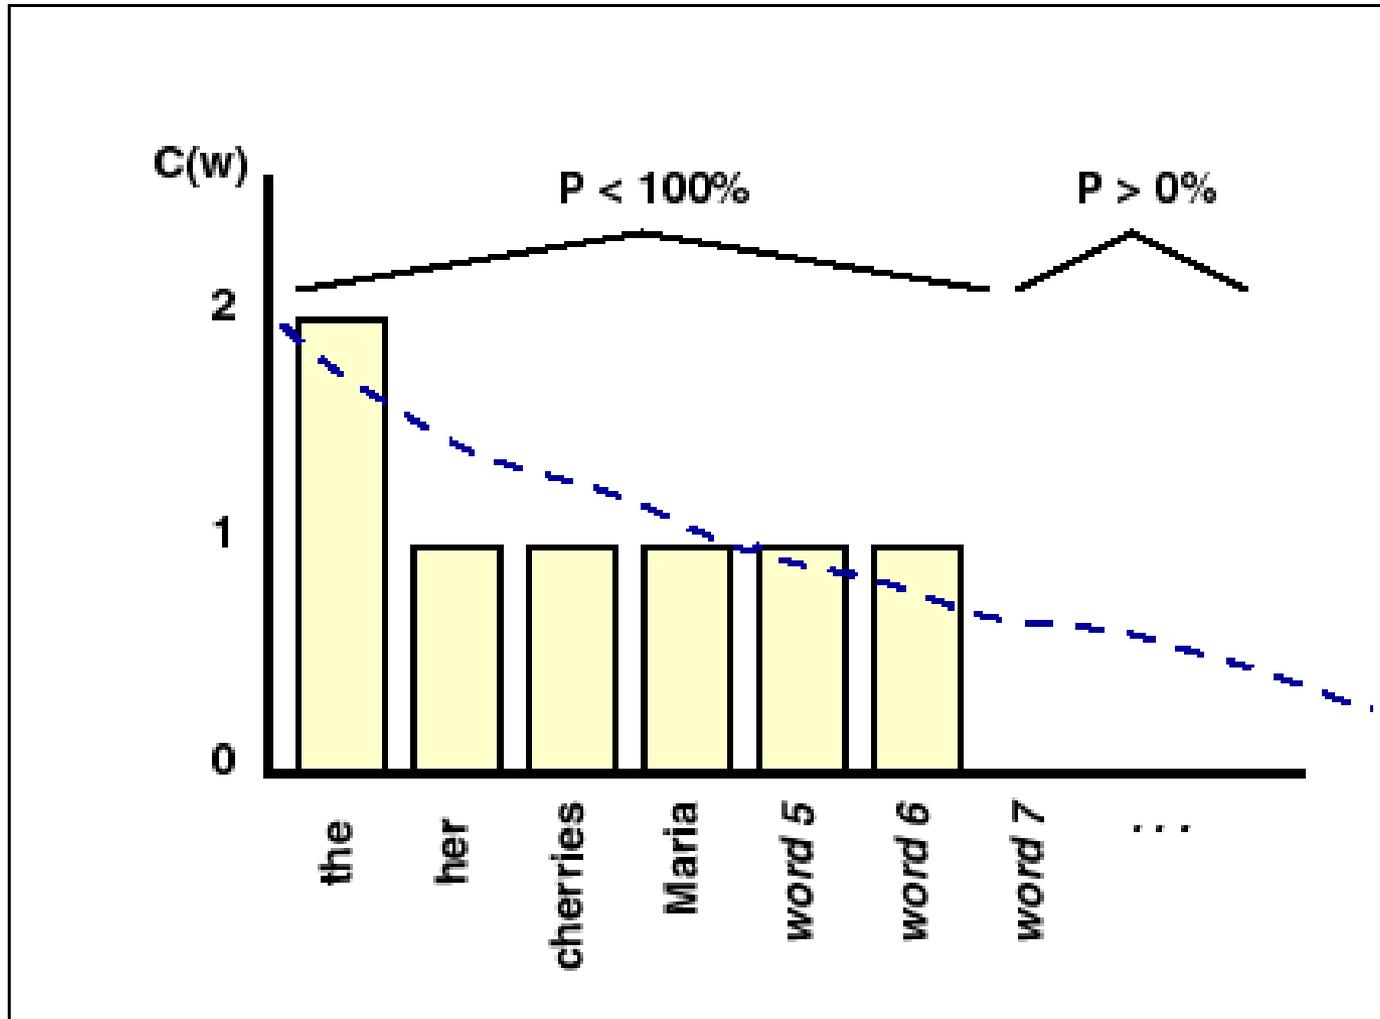
Частотные оценки (MLE):



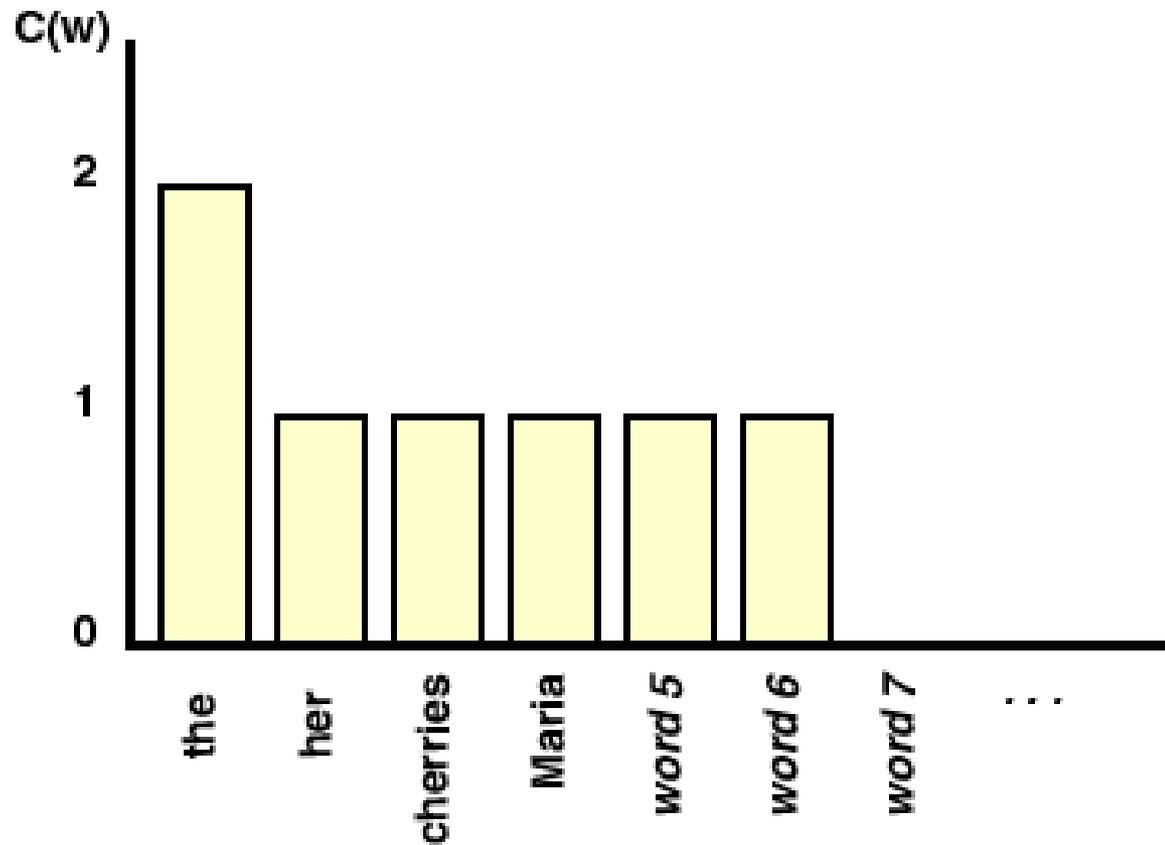
Реальное распределение вероятностей



Реальное распределение вероятностей

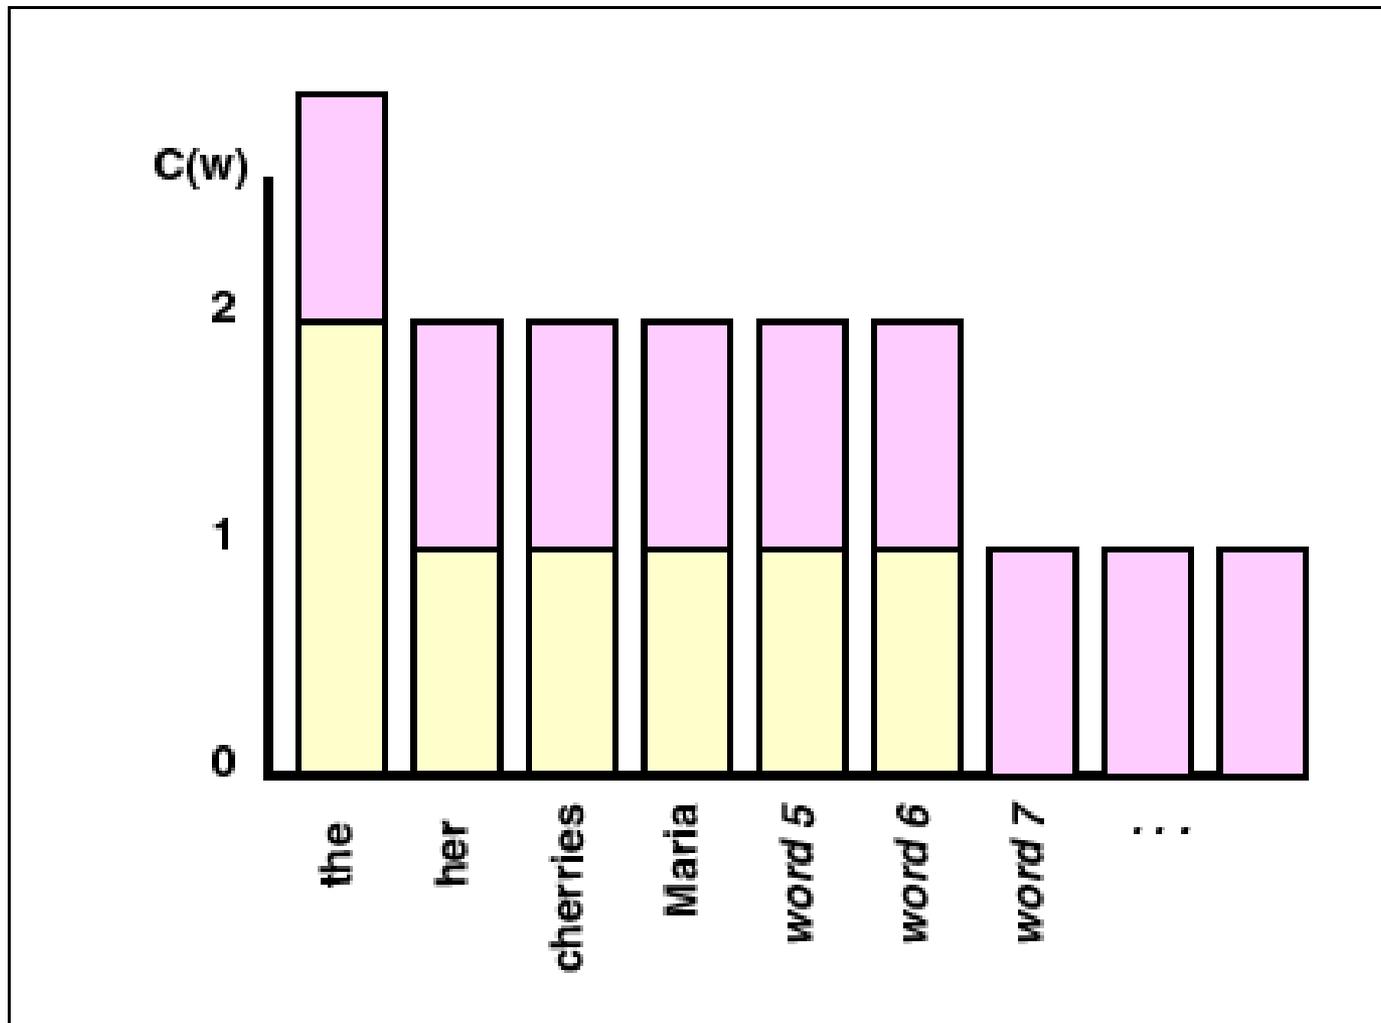


LaPlace's Law *(adding one)*



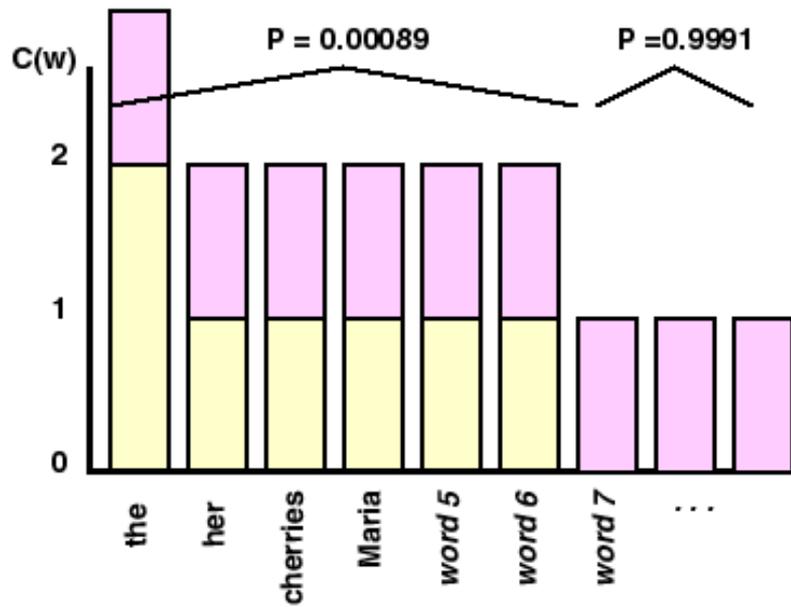
LaPlace's Law

(adding one)



Закон Лапласа

- Более мягкое сглаживание



$$P(w_i) = \frac{C(w_i) + \alpha}{N + \alpha \cdot V}$$

$$P(w_n | w_{n-1}) = \frac{C(w_{n-1}, w_n) + \alpha}{C(w_{n-1}) + \alpha \cdot V}$$

Пример

- Корпус
 - `<s> Он пошел в школу </s>`
 - `<s> Пошел он в школу</s>`
 - `<s> Он не любит мясо</s>`
- Вероятности по Лапласу?:
 - Униграммы: он, пошел, мясо
 - Биграммы: $P(\text{он}|\text{пошел})$, $P(\text{пошел}|\text{он})$

Однако

- Для больших словарей – биграмм всегда много – закон Лапласа дает слишком много вероятности не встречавшимся событиям
- (Church, Gale, 1991)
- Corpus Associated Press – 44 млн. слов – разделили на две части и пытались предсказать поведение на второй части
- - 400653 разных слов
- - $1.6 * 10^{11}$ число возможных биграмм

Предсказание числа биграмм

- $F_{lap} = ((r+1)/(N+V)) * N$
- Биграммы встречались r – раз в одной половине корпуса
- Нужно предсказать, сколько раз такие биграммы встретятся во второй половине корпуса

- $N=22$ млн. слов
- $V= 273266$ разных слов
- $B=V*V$

Закон Лапласа и реальные частоты

R=fmle	flap	femp
0	0.000137	0.000027
1	0.000274	0.448
2	0.000411	1.25
3	0.000548	2.24
4	0.000685	3.23
5	0.000822	4.21
6	0.000959	5.23

Flap – предсказание средней частоты во второй части по Лапласу

Femp – реальная средняя частота во второй части

Недостатки!! Метод негибкий, использует очень мало информации об обучающем корпусе

Еще идея для сглаживания

- Использовать $p(t_n/t_2 \dots t_{n-1})$ для вычисления $p(t_n/t_1 \dots t_{n-1})$, если $C(t_n/t_1 \dots t_{n-1})=0$
- Модели
 - Откат
 - Интерполяционная модель

Katz's Backing-Off (Модель отката)

- Используем *n-gram* вероятность, когда достаточно данных
 - (когда частота $> k$; $k = \{0, 1\}$)
- Если нет, то переходим (“back-off”) на *(n-1)-граммную* вероятность
- (Повторяем при необходимости)
- Модель отката и интерполяционная модель оперируют одними и теми же вероятностями
 - но интерполяционная их суммирует
 - модель отката просто переходит на меньшие энграммы, если не хватает информации

Простая линейная интерполяция (a.k.a., finite mixture models; a.k.a., deleted interpolation)

$$P_{li}(w_n | w_{n-2}, w_{n-1}) =$$

$$\lambda_1 P_1(w_n) + \lambda_2 P_2(w_n | w_{n-1}) + \lambda_3 P_3(w_n | w_{n-2}, w_{n-1})$$

- Взвешенное среднее униграмм, биграмм и триграмм
- Сумма лямбда = 1
-

Пример

- Корпус
 - `<s> Он пошел в школу </s>`
 - `<s> Пошел он в школу</s>`
 - `<s> Он не любит мясо</s>`
- Пусть используется линейная комбинация униграмм, биграмм и триграмм: $\lambda = 1/3$
- Какова вероятность $P(v|\text{он, пошел})$

Подбор параметров

- Hold out ~ 5 – 10% для тестирования
- Hold out ~ 10% для подбора параметров (smoothing)
- Для тестирования: полезно тестировать на разных коллекциях, и исследовать поведение моделей
- Параметры может быть трудно подбирать.

Рекурсивная интерполяционная модель

$$p_{interp}(w_i | w_{i-n+1}^{i-1}) = \lambda_{w_{i-n+1}^{i-1}} p_{ML}(w_i | w_{i-n+1}^{i-1}) + (1 - \lambda_{w_{i-n+1}^{i-1}}) p_{interp}(w_i | w_{i-n+2}^{i-1})$$

- Модель n-го порядка определяется рекурсивно через модели низких порядков
- $p_n()$ – это корпусная вероятность
- λ - коэффициент, зависящий от $w_1 \dots w_{n-1}$
- Чем больше λ , тем больше мы доверяем истории $w_{1, n-1}$
- Много случайных продолжений $w_{1, n-1}$: λ мало
- Продолжений мало и они частотные: $\lambda \approx 1$
- Как определить такие λ ?

Для биграмм

- $P_{\text{interp}}(w_2|w_1) = \lambda p_{\text{ML}}(w_2|w_1) + (1 - \lambda) p_{\text{interp}}(w_2)$

Рекурсивная интерполяционная модель

- Разнообразиие предсказанных слов.
- Рассмотрим в корпусе Europarl биграммные истории слов “spite” и “constant”
 - Одинаковая частотность в корпусе 993
 - Только 9 разных слов после “spite”, почти всегда стоит “of ” (979 раз)
 - 415 различных слов после “constant”:
 - and (45), concern (27), pressure (26)...
- Это означает, что более вероятно увидеть новую слово (новую бигramму) после слова “constant”

Witten-Bell smoothing

- Интуиция: вероятность увидеть энграмму с нулевой вероятностью свяжем с вероятностью увидеть энграмму первый раз:
- $w_1 \dots w_2 \dots w_1 \dots w_2 \dots w_3 \dots$



- $w_1 \dots \text{new } w_2 \dots w_1 \dots w_2 \dots \text{new } w_3 \dots$

Witten-Bell smoothing

- Метод рекурсивной интерполяции
- Смотрим, сколько возможных продолжений в обучающих данных
- $1 - \lambda$ - это вероятность необходимости использовать переход на энграммы более низкого порядка.
- Рассмотрим, сколько разных слов встречалось после нграммы $w_1 \dots w_{n-1}$

$$N_{1+}(w_1, \dots, w_{n-1}, \bullet) = |\{w_n : c(w_1, \dots, w_{n-1}, w_n) > 0\}|$$

$$1 - \lambda_{w_1, \dots, w_{n-1}} = \frac{N_{1+}(w_1, \dots, w_{n-1}, \bullet)}{N_{1+}(w_1, \dots, w_{n-1}, \bullet) + \sum_{w_n} c(w_1, \dots, w_{n-1}, w_n)}$$

Результат для spite и constant

$$\begin{aligned} 1 - \lambda_{spite} &= \frac{N_{1+}(spite, \bullet)}{N_{1+}(spite, \bullet) + \sum_{w_n} c(spite, w_n)} \\ &= \frac{9}{9 + 993} = 0.00898 \end{aligned}$$

$$\begin{aligned} 1 - \lambda_{constant} &= \frac{N_{1+}(constant, \bullet)}{N_{1+}(constant, \bullet) + \sum_{w_n} c(constant, w_n)} \\ &= \frac{415}{415 + 993} = 0.29474 \end{aligned}$$

Проблема сглаживания Виттена-Белла

- Слово York – м.б. достаточно частотное в коллекции
- Поэтому сглаживание по униграммным вероятностям будет предполагать его достаточно частую встречаемость после разных слов
- Но оно встречается только после слова New
- Проблема: переход на униграммные вероятности дает преувеличенные оценки появления слова в биграмме

Сглаживание Кнейзера Нея (Kneser-Ney Smoothing)

- Рассматривает историю появления слова
- Определим: количество разных энграмм, в которых участвует данное слово

$$N_{1+}(\bullet w_i) = |\{w_{i-1} : c(w_{i-1}w_i) > 0\}|$$

$$N_{1+}(\bullet \bullet) = \sum_{w_i} N_{1+}(\bullet w_i)$$

- Тогда для модели низкого порядка

$$p_{KN}(w_i) = \frac{N_{1+}(\bullet w_i)}{N_{1+}(\bullet \bullet)}$$

Т.е. вероятность слова определяется не его частотой во всем объеме коллекции,
А разнообразием словосочетаний, в которые оно входит

Сглаживание Кнейзера Нея (Kneser-Ney Smoothing)

- Рассматривает историю появления слова
- Униграммная вероятность в биграммной модели считается так:
- - число разных биграмм, где второе слово w_i по отношению ко всем биграммам в корпусе

$$\hat{p}(w_i) = \frac{N_{1+}(\bullet w_i)}{N_{1+}(\bullet\bullet)}$$

- Ранее униграммная вероятность была
- $P(w_i) = C(w_i) / N$

Как оценить качество языковой модели?

- Обучение на большей части коллекции (Train)
- Проверка на меньшей части (Test)
- Найти вероятность появления коллекции Test – слишком маленькая величина
- Перплексия (Perplexity)

Перплексия

- Перплексия:

$$PP(W) = P(w_1 w_2 \dots w_N)^{-\frac{1}{N}}$$

- Перплексия – это среднее число вариантов, из которых происходит выбор на каждом шаге.
 - Минимизация перплексии – это максимизация вероятности текста
 - Перплексия для предложения, состоящего из случайной последовательности цифр=10

Перплексия для униграмм и биграмм

Униграммы:

$$PP(W) = P(w_1 w_2 \dots w_N) = \sqrt[N]{\frac{1}{P(w_1 w_2 \dots w_N)}} = \sqrt[N]{\prod_{i=1}^N \frac{1}{P(w_i)}}$$

Биграммы:

$$PP(W) = \sqrt[N]{\prod_{i=1}^N \frac{1}{P(w_i | w_{i-1})}}$$

Расчеты:

$$PP = 2^{-\frac{1}{N} \sum_1^N \log_2 p(x)}$$

Оценка качества языковой модели Корпус EuroParl

Перплексия - чем меньше, тем лучше

Smoothing method	bigram	trigram	4-gram
Good-Turing	96.2	62.9	59.9
Witten-Bell	97.1	63.8	60.4
Modified Kneser-Ney	95.4	61.6	58.6
Interpolated Modified Kneser-Ney	94.5	59.3	54.0

Проблемы энграммных моделей

- Много нулевых вероятностей
 - Решение: группирование слов
 - Заранее созданные классы слов
 - Группирование по одинаковым контекстам встречаемости
- Не учитываются дистантные и разрывные связи
 - В большом зеленом **доме**

Заключение

- Языковые модели присваивают более высокую вероятность предложениям, которые реально встречаются в языке.
- Они используются как компоненты многих систем автоматической обработки текстов, включая распознавание речи и статистический машинный перевод.
- Частотный подход (MLE) дает неточные оценки параметров для разреженного корпуса.
- Техники сглаживания настраивают параметры для оценки вероятности слов, которые не встречались в обучающем корпусе
- В настоящее время новые подходы – на основе нейронных сетей