

# Математические модели в лингвистике

## Коллокации и их автоматическое определение.

Мати Пентус, Александр Пиперски, Алексей Сорокин

МГУ им. М. В. Ломоносова, межфакультетский курс,  
осенний семестр 2017–2018 учебного года

## Композициональность

- В языке потенциально неограниченное число предложений и тем более текстов.
- Однако носитель языка способен восстановить значение элементов более высокого уровня.
- Значение предложений сводится к значению словосочетаний, а значения словосочетания — к значению слов...
- Естественный язык обладает композициональностью:

“Значение сложного выражения есть функция значений его частей и синтаксических правил, соединяющих эти части.”

## Пример композициональности

- То есть определение должно единообразно модифицировать значение существительного, к которому оно относится:
  - *дом* → *красный дом*,
  - *сапог* → *красный сапог*,
  - *куртка* → *красная куртка*
- Однако не всегда смысл изменяется одинаковым образом:
  - *уголок* → *красный уголок*,
  - *армия* → *Красная Армия*,
  - *книга* → *Красная Книга*
- То есть композициональность часто нарушается.

## Нарушения композициональности

- Основной пример: идиомы и фразеологизмы.
- Классификация по В. В. Виноградову:
  - Фразеологические сращения (смысл выражения не восстанавливается по смыслу его компонентов):  
“ни в зуб ногой”, “собаку съесть”.
  - Фразеологические единства (смысл частично восстанавливается по значению компонентов):  
“делать из мухи слона”, “плыть по течению”, “звонить в колокола”
  - Фразеологические сочетания (устойчивое сочетание слов, чей смысл восстановим из значения компонентов, одно из слов менее свободно чем другое):  
“потупить взгляд”, “нанести урон”, “обрести спокойствие”.

## Нарушения композициональности

- Основной пример: идиомы и фразеологизмы.
- Классификация по А. Баранову и Д. Добровольскому:
  - Идиомы (“шишка на ровном месте”),
  - Коллокации (“зло берёт”),
  - Пословицы (“цыплят по осени считают”),
  - Грамматические фразеологизмы (“во что бы то ни стало”),
  - Синтаксические фразеологизмы (Х он и в Африке Х).
- Существуют и другие классификации и определения.

## Варианты определения коллокаций

- “неслучайное сочетание двух и более лексических единиц, характерное как для языка в целом, так и определенного типа текстов”(Ягунова, Пивоварова, 2010).
- “семантическая фразема, такая что в состав её означаемого входит означаемое одной из лексем в качестве семантической доминанты и означаемое второй лексемы в качестве некоторого дополнительного компонента, причём вторая лексема выбирается в зависимости от первой” (Иорданская, Мельчук, 2007).
- “lexically and/or pragmatically constrained recurrent co-occurrences of at least two lexical items which are in a direct syntactic relation with each other” (Bartsch, 2004).

## Вычислительный подход к коллокациям

- “Collocations of a given word are statements of the habitual and customary places of that word.” (Firth, 1957).
- “Collocations [ are ] recurrent combinations of words that co-occur more often than expected by chance and that correspond to arbitrary word usages” (Smadja, 1993).
- “A collocation is a word combination whose semantic and/or syntactic properties cannot be fully predicted from those of its components, and which therefore has to be listed in a lexicon.” (Evert, 2007)
- “I use collocation thus as a generic term whose specific meaning can be narrowed down according to the requirements of a particular research question or application.” (Evert, 2004)

# Основные свойства коллокаций

Основные свойства коллокаций:

- Некомпозициональность — значение коллокации не сводится к значению элементов:

*сыграть в ящик*  $\neq$  *сыграть + ящик*

- Нерегулярность — коллокации не порождаются в соответствии со стандартной моделью.
- Устойчивость — элементы коллокации нельзя заменить на синонимичные.

*крепкий чай*  $\neq$  *сильный чай*

- Частотность.

## Применения коллокаций

Какие есть применения у коллокаций?

- Лексикология (как компьютерная, так и традиционная).
- Подготовка словарей (как дву-, так и одноязычных).
- Автоматический перевод:

A leopard cannot change its spots



Чёрного кобеля не отмоешь добела

## Применения коллокаций

- Уточнение языковых моделей.
- Информационный поиск:

*Дума наложила вето ... ↔ Дума отвергла ...*

- Автоматическая разметка (морфологическая, синтаксическая и т.д):
  - Коллокации могут нарушать морфологические закономерности:  
*задать перцу, ни в зуб ногой, ...*
  - Может использоваться нестандартный порядок слов:  
*справедливости ради, бил озноб.*
  - Морфология и синтаксис элементов коллокации известны:  
*во что бы то ни стало, кто в лес, кто по дрова*

# Наш подход к коллокациям

Мы придерживаемся статистического подхода к коллокациям:

## Определение коллокаций

Коллокация — это сочетание слов (возможно, синтаксически связанных), частотность которого существенно выше, чем была бы в предположении о независимости его компонент.

Математически,

$$c(w_1 w_2) \gg c(w_1)c(w_2),$$

где  $c(\alpha)$  — относительная частота сегмента  $\alpha$  в корпусе.

То есть надо вычислять *взаимную информацию* слов  $w_1$  и  $w_2$ :

$$MI(w_1, w_2) = \log \frac{c(w_1 w_2)}{c(w_1)c(w_2)}$$

# Этап 1: создание конкорданса

## Создание конкорданса при помощи SketchEngine:

Query (в)-s 34,220,576 (27,291.0 per million) | using first 10,000,000 lines only (use random).

Page 1 of 500,000 Go Next | Last

doc#0 другого года, даже если виноград собран в пределах одного виноградника. Истинные  
 doc#0 загородными домами, с удовольствием устраивают в них винные погреба. </p><p> Вино - напиток  
 doc#0 хранения обируют специальные винные погреба, в которые в идеале хорошо бы установит систему  
 doc#0 обирудуют специальные винные погреба, в которые в идеале хорошо бы установит систему климат  
 doc#0 очень красиво. </p><p> Для хранения бутылок в винном погребе можно использовать деревянные  
 doc#1 тебе и уважуха)) Вот только минус подборки в том, что ты искал только по тем группам  
 doc#1 Nile. По моему скромному мнению уделяется в плане дизайна большую часть представителей  
 doc#1 анимированная змея и смешные бэкграунды в стиле древнего Египта. А это я только тыкнул  
 doc#2 являются нелинейными. Оттенки отражают различия в свойствах. Количество нелинейных слов  
 doc#2 слов можно выбирать произвольно, но авторы в своих дальнейших вычислениях ограничились  
 doc#2 которую можно определить интенсивность волны в заданном слое N . Эта функция находится  
 doc#2 нелинейного уравнения Шредингера. Подробности см. в тексте. Рисунок из обсуждаемой статьи в  
 doc#2 в тексте. Рисунок из обсуждаемой статьи в Phys. Rev. Lett. </p><p> Итальянские физики-теоретики  
 doc#2 рассчитали параметры структуры, которую в дальнейшем можно использовать для создания  
 doc#2 электромагнитные или акустические волны в одном направлении и полностью их блокировать  
 doc#2 полностью их блокировать, когда они движутся в противоположную сторону. В отличие от предыдущих  
 doc#2 они движутся в противоположную сторону. В отличие от предыдущих теоретических моделей  
 doc#2 устройство, которое пропускает электрический ток в одном направлении и не позволяет ему течь  
 doc#2 одном направлении и не позволяет ему течь в противоположном. Наряду с транзистором  
 doc#2 света или звука, могли бы использоваться в тепло- и звукоизоляции, направленной передаче

## Этап 2: выделение коллокаций

Выделение коллокаций при помощи SketchEngine:

user: Dr. Alexey Sorokin corpus: [ruTenTen \[2011, sample\]](#)

Search

- [Concordance](#)
- [Word List](#)
- [Word Sketch](#)
- [Thesaurus](#)
- [Find X](#)
- [Sketch-Diff](#)
- [Corpus Info](#)
- [?](#)

---

- [< Concordance](#)
- [Sample](#)
- [Filter](#)
- [Overlaps](#)
- [1st hit in doc](#)
- [Frequency](#)
- [Node tags](#)

### Collocation candidates [?](#)

Attribute: 
In the range from:  to:

Minimum frequency in corpus: 
Minimum frequency in given range:

T-score

MI

MI3

log likelihood

min. sensitivity

logDice

T-score

MI

MI3

log likelihood

min. sensitivity

logDice

Show functions: 
Sort by:

[Make Candidate List](#)
[Save Options](#)

## Этап 3: список коллокаций

Получаемый список наиболее частых коллокатов:

### Collocation candidates

Page 1

[Next >](#)

	Freq	MI
P   N Кефиристане	5	6.970
P   N Крайске	5	6.970
P   N Торвил	5	6.970
P   N Красносельске	6	6.970
P   N МЦИпе	5	6.970
P   N энерготическом	5	6.970
P   N Мурниеках	5	6.970
P   N Набадвиле	5	6.970
P   N Эспиньюлях	26	6.970
P   N Падьюке	7	6.970
P   N Хостинг-Центре	5	6.970
P   N Стегеборге	5	6.970
P   N Уранополь	7	6.970
P   N буржнете	8	6.970
P   N квадрапространстве	10	6.970
P   N Печникове	8	6.970
P   N мутазилизме	5	6.970
P   N Клариды	5	6.970
P   N Аксалте	6	6.970

## Анализ результатов

Пусть словоформа  $X$  встречается только внутри биграммы в  $X$ ,  
тогда

$$MI(v, X) = \log \frac{p(v|X)}{p(v)p(X)} = -\log p(v) = 5.19$$

Получилось 6.79, потому что "Although it is labeled as standard "Mutual Information", Sketch Engine actually uses a slightly different calculation: «a scaled version of Dice»". (A. Kilgariff)

## Недостатки взаимной информации

- Пусть корпус содержит 1000000 слов.
- Минимальная ненулевая частота биграммы: 0.000001.
- Значит, для биграммы  $XY$ , где каждое слово имеет частоту 100, получим

$$MI(X, Y) = \log_2 \frac{0.000001}{0.0001 * 0.0001} = \log_2 100 = 6.64$$

- Метод взаимной информации предпочитает редкие слова!
- Для них любая случайная биграмма даёт большое значение информации.
- Вывод: надо рассматривать не абсолютную величину отличия, а его значимость.

## Математическое отступление: проверка гипотез

- Мы будем проверять не то, насколько сильно отклоняется значение, а насколько невероятно такое отклонение.
- Будем считать, что слово  $w$  появляется с вероятностью, равной его относительной частоте:

$$p(u = w) = c(w) = \frac{n(w)}{N}, \text{ где } N \text{ — размер корпуса}$$

- Рассмотрим гипотезу  $H_0$ , что появление слов  $w_1$  и  $w_2$  независимо (это означает, что  $w_1w_2$  не образует коллокацию).
- Тогда биграмма  $w_1w_2$  распределена биномиально с вероятностью

$$p_0 = p(u_1 = w_1)p(u_2 = w_2) = c(w_1)c(w_2)$$

- Гипотеза отсутствия коллокации:  $H_0 : p(w_1w_2) = p_0$ .
- Гипотеза наличия связи (присутствия коллокации):  $H_1 : p(w_1w_2) > p_0$ .

## Уровни значимости

- Пусть корпус содержит  $N$  биграмм, а биграмма  $w_1w_2$  встречается  $p$  раз. Нам требуется подобрать порог частоты  $h$  так, чтобы вероятность ошибочного принятия альтернативной гипотезы  $H_1$  (“ложной тревоги”) была не выше некоторого значения  $p$ .
- То есть при принятии гипотезы мы должны ошибаться с вероятностью не больше  $p$ .
- Предположим, что  $H_0$  верна, тогда в качестве порогового значения для относительной частоты  $c(w_1w_2)$  нужно взять такое  $h$ , что

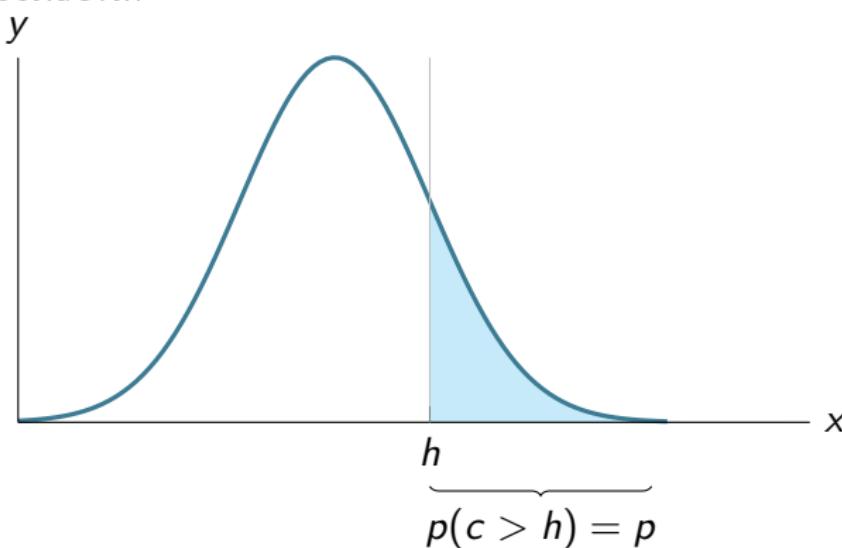
$$p(c > h | H_0) \leq p.$$

- Тогда  $H_1$  принимается если  $c(w_1w_2) \geq h$  или, что то же самое,

$$p(c > c(w_1w_2) | H_0) \leq p.$$

## Уровни значимости

- $H_0$  отвергается (принимается альтернативная гипотеза о наличии коллокации), если  $c$  попадает в проекцию заштрихованной области.



## Уровни значимости

- Найдём вероятность того, что  $p(c \geq c(w_1 w_2))$  при условии  $H_0$ , то есть при условии, что вероятность данной биграммы равна  $p_0 = c(w_1)c(w_2)$ .
- Она задаётся формулой  $\sum_{m=n}^N C_N^m p_0^m (1-p_0)^{N-m}$ , где  $m$  — число вхождений биграммы  $w_1 w_2$  в корпус.
- Если  $\sum_{m=n}^N C_N^m p_0^m (1-p_0)^{N-m} \leq p$ , то гипотезу  $H_0$  можно отвергать с риском ошибиться не более, чем  $p$ .
- То есть в качестве показателя наличия коллокации можно брать величину

$$1 - \sum_{m=n}^N C_N^m p_0^m (1-p_0)^{N-m}$$

- Недостаток: невозможно считать.

# Статистический подход к извлечению коллокаций

- Общая методология: подобрать некоторую статистику  $z$  с функцией распределения  $F$ , монотонно зависящую от числа вхождений биграммы  $w_1 w_2$ .
- Тогда порогом наличия коллокации является либо само значение этой статистики  $z_0$ , либо  $F^{-1}(z_0)$ :

$z \geq z_0$  — принимаем гипотезу о наличии коллокации,  
 $z < z_0$  отвергаем гипотезу

- Лучше всего брать легко вычислимую статистику с известной функцией распределения (например, нормальным или  $\chi^2$ ).

## Нормальное приближение

- Однако распределение нормированной суммы большого числа независимых бернуlliевых величин очень напоминает нормальное. Нельзя ли этим воспользоваться?
- Если предположить, что  $p(w_1 w_2) = p_0$ , то величина  $z(w_1 w_2) = \frac{c(w_1 w_2) - p_0 N}{\sqrt{p_0 N}}$  стремится по распределению к стандартной нормальной величине с плотностью

$$p(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

- Проблема в том, что при малых  $p_0$  сходимость очень медленная, а знаменатель очень мал, поэтому пользоваться этим приближением нельзя.

## Нормальное приближение

- В работе [Church, 1991] была предложена величина

$$t(w_1 w_2) = \frac{c(w_1 w_2) - p_0 N}{\sqrt{c(w_1 w_2)}}$$

- Данная статистика называется  $t$ -мерой для коллокаций

# Извлечение коллокаций с помощью $t$ -меры

Получаемый список наиболее частых коллокатов:

P   N	том	182,902	407.129
P   N	этом	149,908	361.273
P   N	течение	79,760	274.793
P   N	качество	77,418	270.522
P   N	России	82,347	261.724
P   N	результате	64,477	246.876
P   N	рамках	62,678	244.362
P   N	соответствии	62,570	243.973
P   N	случае	61,178	229.087
P   N	конце	51,142	218.857
P   N	области	56,473	214.022
P   N	Москве	48,054	212.279
P   N	где	47,541	209.237
P   N	связи	46,249	202.241
P   N	целом	42,123	199.421
P   N	настоящее	42,080	198.786
P   N	частности	41,590	198.225
P   N	котором	42,715	197.801
P   N	этой	46,253	190.531
P   N	зависимости	37,361	187.205
P   N	основном	36,151	184.666
P   N	ходе	35,978	184.058
P   N	мире	36,065	181.299
P   N	нем	34,109	176.181

## Недостаток $t$ -меры

- $t$ -мера зависит лишь от  $c(w_1 w_2)$  и произведения  $e(w_1 w_2) = c(w_1)c(w_2)$ .
- Воображаемый пример (Evert, 2007):

$$\begin{aligned} C(Iliad) &= 10, & C(the) &= 100000, \\ C(must) &= 1000, & C(also) &= 1000, \\ C(the\ Iliad) &= 10, & C(must\ also) &= 10 \\ E(the\ Iliad) &= 10^6, & E(must\ also) &= 10^6 \end{aligned}$$

- То есть с точки зрения  $t$ -меры данные биграммы в одинаковой степени являются коллокациями.
- Различие: *must* и *also* встречаются со многими другими словами, *Iliad* — только с *the*.
- Следовательно, одной “положительной” информации недостаточно.
- Выход: нужно рассматривать всю таблицу сопряжённости биграм  $w_1$  и  $w_2$ .

## Таблицы сопряжённости

Таблица сопряжённости показывает совместное распределение вхождений  $w_1$  и  $w_2$ .

	$w_2$	$\neg w_2$	
$w_1$	$n_{11}$	$n_{12}$	$L_1$
$\neg w_1$	$n_{21}$	$n_{22}$	$L_2$
	$R_1$	$R_2$	$N$

$$n_{11} = c(w_1, w_2)$$

$$n_{12} = c(w_1, \cdot) - c(w_1, w_2) = \sum_{w \in T_2, w \neq w_2} c(w_1, w)$$

$$n_{21} = c(\cdot, w_2) - c(w_1, w_2) = \sum_{w \in T_1, w \neq w_1} c(w, w_2)$$

$$\begin{aligned} n_{22} &= c(\cdot, \cdot) - c(w_1, \cdot) - c(\cdot, w_2) + c(w_1, w_2) \\ &= \sum_{\substack{u \in T_1, v \in T_2 \\ u \neq w_1, v \neq w_2}} c(u, v) \end{aligned}$$

Здесь  $T_1, T_2$  — множества слов, откуда берутся  $w_1, w_2$ .

## Меры коллокативности для таблиц сопряжённости

Пусть  $e_{11} = p_1 p_2$ ,  $e_{12} = p_1 \bar{p}_2$ ,  $e_{21} = \bar{p}_1 p_2$ ,  $e_{22} = \bar{p}_1 \bar{p}_2$  — ожидаемые значения элементов таблицы.

$$MI_a(w_1, w_2) = \sum_{i,j} c_{ij} \log_2 \frac{c_{ij}}{e_{ij}} \text{ средняя взаимная информация}$$

$$\chi^2(w_1, w_2) = \sum_{i,j} \frac{(c_{ij} - e_{ij})^2}{e_{ij}} \text{ статистика } \chi^2$$

$$OR(w_1, w_2) \approx \frac{c_{11}}{c_{21}} / \frac{c_{12}}{c_{22}} = \frac{(c_{11} + 0.5)(c_{22} + 0.5)}{(c_{12} + 0.5)(c_{21} + 0.5)}$$

$$D_1(w_1, w_2) = \frac{n_{11}}{L_1} \quad D_2(w_1, w_2) = \frac{n_{11}}{R_1}$$

$$Dice(w_1, w_2) = \frac{2D_1 D_2}{D_1 + D_2} = \frac{2n_{11}}{L_1 + R_1}$$

И ещё примерно 80 вариантов (Pecina, 2005)

# Таблица мер коллокативности

1. Mean component offset	$\frac{1}{n} \sum_{i=1}^n d_i$
2. Variance component offset	$\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2$
3. Joint probability	$P(xy)$
4. Conditional probability	$P(y x)$
5. Reverse conditional prob.	$P(x y)$
*6. Pointwise mutual inform.	$\log \frac{P(xy)}{P(x)P(y)}$
7. Mutual dependency (MD)	$\log \frac{P(xy)}{P(x)P(y)}$
8. Log frequency biased MD	$\log \frac{P(xy)}{P(x)P(y)} + \log P(xy)$
9. Normalized expectation	$\frac{P(xy)}{f(x)f(y)}$
*10. Mutual expectation	$f(x,y) / f(x)f(y)$
11. Salience	$\log \frac{f(x,y)}{f(x)f(y)} - P(xy)$
12. Pearson's $\chi^2$ test	$\sum_{ij} \frac{(O_{ij} - E_{ij})^2}{E_{ij}}$
13. Fisher's exact test	$\frac{P(x_1, y_1)P(x_2, y_2)P(x_3, y_3)P(x_4, y_4)}{P(x_1, y_1)P(x_2, y_2)P(x_3, y_3)P(x_4, y_4)}$
14. t-test	$\sqrt{f(x,y)(1-(f(x,y)/N))}$
15. z-score	$\frac{f(x,y)(1-(f(x,y)/N))}{f(x,y)}$
16. Poisson significance measure	$\frac{\chi^2}{\log N}$
17. Log likelihood ratio	$-2 \sum_{ij} O_{ij} \log \frac{O_{ij}}{E_{ij}}$
18. Squared log likelihood ratio	$-2 \sum_{ij} O_{ij} \frac{\log O_{ij}^2}{E_{ij}}$

## Сравнение различных мер

- $MI$  — чувствительна к случайным совпадениям, находит тематические коллокации.
- $t$ -мера — смещена в сторону частотных пар, находит устойчивые сочетания, но не имеет строгого обоснования.
- *Dice*-мера — находит симметричные устойчивые сочетания ( $w_1$  и  $w_2$  встречаются только вместе).
- Отношение вероятностей не отличает положительную и отрицательную ассоциацию.
- Выбор оптимальной меры зависит от задачи (например, нужны ли симметричные или несимметричные коллокации).

## Варианты определения коллокаций

- Мы считали статистику “по словам”, используя счётчики для словоформ.
- Можно считать “по леммам”, используя счётчики для лексем.
- Например, для биграммы “придать значение” это позволит отследить все формы глагола:
  - “придаёт значение”
  - “придала значение”
  - “придадим значение”
  - и даже “не придаёт значения”.

# Сравнение коллокаций по словам и леммам.

Коллокации глагола *придать* “по словам”.

## Collocation candidates

Page

[Go](#)

[Next >](#)

Frequency	T-score
715	26.522
496	22.174
449	21.072
433	20.552
314	17.424
296	17.185
213	14.540
193	13.749
166	12.221
137	11.686
136	11.649
127	11.166
141	10.590
107	10.258
91	9.505
89	9.431
86	9.252
85	8.915

<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>ему</b>	Frequency	T-score
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>этому</b>	496	22.174
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>ей</b>	449	21.072
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>им</b>	433	20.552
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>вам</b>	314	17.424
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>вашему</b>	296	17.185
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>значения</b>	213	14.540
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>новый</b>	193	13.749
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>мне</b>	166	12.221
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>Вашему</b>	137	11.686
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>уверенности</b>	136	11.649
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>сил</b>	127	11.166
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>бы</b>	141	10.590
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>вашей</b>	107	10.258
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>вашим</b>	91	9.505
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>интерьеру</b>	89	9.431
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>дополнительный</b>	86	9.252
<a href="#">П</a> <a href="#">И</a> <a href="#">Н</a> <b>Вам</b>	85	8.915

# Сравнение коллокаций по словам и леммам.

Коллокации глагола *придать* “по леммам”.

## Collocation candidates

Page 1

[Go](#)

[Next >](#)

		Frequency	T-score		
P	I	N	ваш	710	26.260
P	I	N	он	788	25.240
P	I	N	этот	600	22.330
P	I	N	она	459	20.202
P	I	N	они	463	18.974
P	I	N	вы	401	18.282
P	I	N	значение	252	15.691
P	I	N	новый	277	15.605
P	I	N	сила	208	14.009
P	I	N	особый	181	13.260
P	I	N	уверенность	163	12.724
P	I	N	дополнительный	167	12.703
P	I	N	бы	141	10.588
P	I	N	интерьер	89	9.348
P	I	N	форма	83	8.494
P	I	N	я	170	8.484
P	I	N	свой	128	8.364
P	I	N	кожа	73	8.286

## Варианты определения коллокаций

- Мы рассматривали только непосредственные биграммы, чьи элементы примыкают друг к другу.
- Однако это не всегда оправдано:
  - придать большое значение,
  - придать существенное значение,
  - не придать никакого значения.
- для некоторых коллокаций вероятней “разрывная” биграмма:
  - “взять X назад”, “по Y счёту”
- Можно рассматривать не просто биграммы, а биграммы, находящиеся внутри окна фиксированной ширины (чаще всего берут  $w = 5$ ).
- Тогда формулы для взаимной информации и  $t$ -меры можно использовать без изменения.

# Сравнение различных коллокаций.

Коллокации глагола *придать* “по словам”,  $d = 1$ .

## Collocation candidates

Page

1

Go

[Next >](#)

	Frequency	T-score
P I N ему	715	26.522
P I N этому	496	22.174
P I N ей	449	21.072
P I N им	433	20.552
P I N вам	314	17.424
P I N вашему	296	17.185
P I N значения	213	14.540
P I N новый	193	13.749
P I N мне	166	12.221
P I N Вашему	137	11.686
P I N уверенности	136	11.649
P I N сил	127	11.166
P I N бы	141	10.590
P I N вашей	107	10.258
P I N вашим	91	9.505
P I N интерьеру	89	9.431
P I N дополнительный	86	9.252
P I N Вам	85	8.915

# Сравнение различных коллокаций.

Коллокации глагола *придать* “по словам”,  $d = 2$ .

## Collocation candidates

Page

1

Go

[Next >](#)

	<u>Frequency</u>	<u>T-score</u>
P I N ему	723	26.672
P I N значения	564	23.715
P I N этому	550	23.360
P I N ей	457	21.261
P I N им	440	20.722
P I N уверенности	350	18.700
P I N вашему	344	18.529
P I N импульс	313	17.687
P I N вам	316	17.482
P I N сил	306	17.426
P I N форму	256	15.951
P I N новый	243	15.461
P I N силы	161	12.579
P I N Вашему	158	12.552
P I N мне	171	12.423
P I N интерьеру	150	12.245
P I N особый	144	11.980
P I N вид	143	11.816

## Синтаксические коллокации

- Часто найденные коллокации не оказываются синтаксически связанными:
- Некоторые коллокации, найденные на материале НКРЯ:
  1. потому что
  2. может быть
  3. у меня
  - ...
  - ...
  8. том что
  11. ничего не
  13. я не
- Вывод: надо рассматривать только пары слов, связанные синтаксической зависимостью.
- Что произойдёт с вероятностной моделью?

## Уточнение вероятностной модели

- Наблюдение: почти для любой биграммы  $p(w_1 w_2) \gg p(w_1)p(w_2)$ .
- **Почему это так?**
- Элементы биграммы не могут относиться к произвольным синтаксическим и морфологическим категориям.
- Чем может быть  $x$  в паре “придать  $x$ ”:
  - Существительным в винительном падеже (“придать смысл”),
  - Прилагательным в винительном падеже (“придать неожиданный смысл”),
  - Наречием (“придать довольно неожиданный смысл”),
  - Существительным или прилагательным в дательном падеже: “придать фразе довольно двусмысленное звучание”

## Уточнение вероятностной модели

- При вычислении ожидаемой вероятности мы предполагали, что все слова допустимы после  $w_1$ .
- Но это не так (даже в отсутствие коллокативности).
- Например, за предлогом не может идти глагол.
- Соответственно, в выражении “придать  $x$ ” вариант  $x = “значение”$  “конкурирует” в основном с существительными и прилагательными в винительном падеже.
- Если мы рассматриваем только биграммы, соединённые синтаксической связью, то оно конкурирует только с прямыми дополнениями при глаголе “придать”.
- Как это учесть в модели?

## Уточнение вероятностной модели

- Нужно считать только вхождения  $w_1, w_2$ , находящиеся в биграммах заданного типа (например, “предлог + существительное”).
- Формально, пусть  $c_1, c_2$  — категории в биграмме  $w_1 w_2$ .
- Тогда формула взаимной информации примет вид:

$$\begin{aligned} MI(w_1 w_2 | c_1 c_2) &= \log c(w_1 w_2 | c_1 c_2) - \log c(w_1 | c_1 c_2) \\ &\quad - \log c(\_w_2 | c_1 c_2), \text{ где} \\ c(w_1 w_2 | c_1 c_2) &= \#(w_1 w_2 | c(w_1) = c_1, c(w_2) = c_2), \\ c(w_1 | c_1 c_2) &= \sum_{u_2} \#(w_1 u_2 | c(w_1) = c_1, c(u_2) = c_2), \\ c(\_w_2 | c_1 c_2) &= \sum_{u_1} \#(u_1 w_2 | c(u_1) = c_1, c(w_2) = c_2), \end{aligned}$$

- Аналогично, в формулах для  $t$ -меры и в таблицах сопряжённости в качестве суммарной длины надо брать

$$c(\_\_ | c_1 c_2) = \sum_{u_1, u_2} \#(u_1 u_2 | c(u_1) = c_1, c(u_2) = c_2)$$

## Таблицы сопряжённости: напоминание

	$w_2$	$\neg w_2$	
$w_1$	$n_{11}$	$n_{12}$	$L_1$
$\neg w_1$	$n_{21}$	$n_{22}$	$L_2$
	$R_1$	$R_2$	$N$

$$n_{11} = c(w_1, w_2)$$

$$n_{12} = \sum_{\substack{w \in T_2, \\ w \neq w_2}} c(w_1, w)$$

$$n_{21} = \sum_{\substack{w \in T_1, \\ w \neq w_1}} c(w, w_2)$$

$$n_{22} = \sum_{\substack{u \in T_1, v \in T_2 \\ u \neq w_1, v \neq w_2}} c(u, v)$$

Здесь  $T_1$ ,  $T_2$  — множества слов, откуда берутся  $w_1$ ,  $w_2$ .

Например,  $T_1$  — переходные глаголы,  $T_2$  — прямые дополнения.