

Статистические критерии адекватности вероятностных тематических моделей коллекции текстовых документов

6 июня 2013 г.

1 Введение

Тематическое моделирование (topic modeling) — одно из активно развивающихся приложений машинного обучения к анализу текстов [9]. *Тематическая модель* коллекции текстовых документов определяет, к каким темам относится каждый документ, и какие термины образуют каждую тему. *Вероятностная тематическая модель* описывает каждую тему дискретным распределением на множестве терминов, каждый документ — дискретным распределением на множестве тем. Это позволяет решать задачи классификации, кластеризации и категоризации текстов, а также создавать тематические поисковые системы, позволяющие по тексту произвольной длины находить документы схожей тематики. Кроме того, тематические модели широко используются в области компьютерного зрения: для классификации изображений [1], определения подписей к ним [2] и построения иерархий [3, 4].

Исходными данными для тематической модели является множество (коллекция) текстовых документов D и множество (словарь) терминов W . Каждый документ $d \in D$ представляется последовательностью терминов (w_1, \dots, w_{n_d}) из W , где n_d — длина документа. Через n_{dw} обозначается число вхождений термина w в документ d .

Латентно-семантический анализ [5] (латентно-семантическое индексирование в информационном поиске) — метод обработки информации, анализирующий взаимосвязь между документами и встречающимися в них терминами путем представления документов и терминов в пространстве так называемых “тем”. Для этого используется сингулярное разложение матрицы слов-на-документы A , обычно содержащей в качестве элементов веса, учитывающие частоты использования каждого термина в каждом документе и участие термина во всех документах (tf-idf). Иначе говоря, матрица A представляется в виде произведения трех матриц:

$$A = U\Lambda V^T,$$

где U и V — ортогональные матрицы, а Λ — диагональная матрица, на диагонали которой — собственные значения AA^T , называемые сингулярными значениями матрицы A . Оставляя k наибольших диагональных элементов матрицы Λ и взяв соответствующие им столбцы матриц U и V , получается матрица

$$A_k = U_k \Lambda_k V_k^T$$

ранга k , которая является лучшей аппроксимацией исходной матрицы A среди матриц заданного ранга k (минимизирует норму Фробениуса разности матриц [16]). Таким образом, каждый термин и документ представляется в общем пространстве размерности k , что позволяет определять близость между документами, терминами или документами и терминами как косинус угла между соответствующими векторами. Латентно-семантический анализ используется для классификации документов, кластеризации, поиска информации, позволяет решать проблемы, связанные с синонимией терминов [6].

Вероятностный латентно-семантический анализ, появившийся в 1999 году [10], является дальнейшим развитием *латентно-семантического анализа*, в отличие от которого имеет строгое статистическое обоснование и определяет модель порождения коллекции документов. Кроме того, данный метод позволяет разделять различные значения слов, тем самым решая проблемы, связанные с полисимией (многозначностью). Вероятностный латентный семантический анализ основывается на представлении вероятности появления пары “документ-термин” следующим образом:

$$p(d, w) = \sum_{t \in T} p(t)p(w|t)p(d|t) = \sum_{t \in T} p(d)p(w|t)p(t|d) = \sum_{t \in T} p(w)p(t|w)p(d|t),$$

где t —скрытая переменная(тема). Неизвестные вероятности $p(w|t)$ и $p(t|d)$ для всех $w \in W, t \in T, d \in D$ определяются из решения задачи максимизации логарифма правдоподобия выборки:

$$\sum_{d \in D} \sum_{w \in W} n_{dw} \log \sum_{t \in T} p(w|t)p(t|d) \longrightarrow \max_{\{p(w|t)\}, \{p(t|d)\}}$$

при ограничениях:

$$\begin{cases} p(w|t) \geq 0 & \forall w \in W, t \in T \\ p(t|d) \geq 0 & \forall t \in T, d \in D \\ \sum_{w \in W} p(w|t) = 1 & \forall t \in T \\ \sum_{t \in T} p(t|d) = 1 & \forall d \in D \end{cases}$$

Для решения данной задачи применяется итерационный процесс, каждая итерация которого состоит из двух шагов (EM-алгоритм [11]).

Вероятностная тематическая модель с априорными распределениями Дирихле была предложена Дэвидом Блэем и др. в [12] и названа *латентным размещением Дирихле* (Latent Dirichlet Allocation, LDA). Одним из ключевых предположений модели является то, что распределения тем в документах подчиняются распределению Дирихле. При этом вводится двухуровневая модель порождения каждого документа коллекции $d \in D$, описанная в Алгоритме 1.1. Каждая тема представляет собой распределение вероятностей над словами $p(w|t)$, а каждый документ—распределение вероятностей над темами $p(t|d)$.

Одним из методов решения задачи тематического моделирования LDA является сэмплирование Гиббса, предложенное в [13](Gibbs Sampling, GS). В [14] описан обзор и анализ основных моделей обучения LDA, а в [15]—строгий вывод формул LDA-GS.

Все вероятностные модели основаны на следующих предположениях [10, 12].

Алгоритм 1.1. Порождение документа d в коллекции.

Вход: $p(w | t)$ для всех $w \in W, t \in T$, α —параметр распределения Дирихле;
Выход: последовательность слов документа d ;

- 1: выбрать длину документа n_d ;
 - 2: выбрать распределение тем в документе $p(t | d) \sim Dir(\alpha)$;
 - 3: **для всех** $i = 1 \dots n_d$
 - 4: выбрать тему $t \sim p(t | d)$;
 - 5: выбрать слово $w \sim p(w | t)$;
-

Во-первых, предполагается, что для выявления тематики достаточно знать, какие термины встречаются в каких документах, но не важен ни порядок терминов в документах (*гипотеза «мешка слов»*), ни порядок документов в коллекции (*гипотеза «мешка документов»*). Другими словами, предполагается, что тематику документа можно узнать даже после случайной перестановки терминов, хотя для человека такой текст теряет смысл.

Во-вторых, предполагается, что существует конечное множество тем T и дискретное распределение $p(d, w, t)$ на $D \times W \times T$, порождающее последовательность независимых наблюдений — троек (d_i, w_i, t_i) , $i = 1, \dots, n$. Переменная t является латентной (скрытой), и наблюдаемая коллекция документов представляет собой последовательность пар (d_i, w_i) , $i = 1, \dots, n$, оставшихся после отбрасывания всех тем.

В-третьих, предполагается, что условное распределение вероятностей терминов $p(w | d, t)$ в любом документе d зависит только от темы t , но не от самого документа. Это предположение называется *гипотезой условной независимости*:

$$p(w | d, t) = p(w | t). \quad (1)$$

Его можно представить эквивалентном виде:

$$p(d | w, t) = p(d | t). \quad (2)$$

Согласно формуле полной вероятности и гипотезе условной независимости,

$$p(w | d) = \sum_{t \in T} p(w | t)p(t | d). \quad (3)$$

Построить тематическую модель коллекции — означает по известной левой части $p(w | d) = n_{dw}/n_d$ найти неизвестные условные распределения в правой части: $p(w | t)$ для каждой темы $t \in T$ и $p(t | d)$ для каждого документа $d \in D$, а также определить оптимальное число тем $|T|$.

Большинство тематических моделей [10, 12, 13, 14] оценивают вероятности тем $p(t | d, w)$ для каждого слова w в каждом документе d . Зная эти вероятности, возможно оценить число троек:

$$\begin{aligned} n_{dwt} &= n_{dw}p(t | d, w) — в которых термин w документа d связан с темой t , \\ n_{dt} &= \sum_{w \in W} n_{dwt} — в которых термин документа d связан с темой t , \\ n_{wt} &= \sum_{d \in D} n_{dwt} — в которых термин w связан с темой t , \\ n_t &= \sum_{d \in D} \sum_{w \in W} n_{dwt} — связанных с темой t , \end{aligned}$$

и затем по ним найти частотные оценки искомых условных вероятностей:

$$\begin{aligned}\hat{p}(t | d) &= \frac{n_{dt}}{n_d}, & \hat{p}(w | t) &= \frac{n_{wt}}{n_t}, & \hat{p}(w | d, t) &= \frac{n_{dwt}}{n_{dt}}, \\ \hat{p}(d | w, t) &= \frac{n_{dwt}}{n_{wt}}, & \hat{p}(d | t) &= \frac{n_{dt}}{n_t}.\end{aligned}\quad (4)$$

Выполнение гипотезы условной независимости (2) является важным требованием к вероятностной тематической модели. В [17] предлагается критерий, оценивающий степень несоответствия темы t гипотезе условной независимости. Он основан на дивергенции Кульбака-Лейблера и может быть вычислен в ЕМ-алгоритме:

$$KL_t = KL(\hat{p}(d, w | t) \| \hat{p}(d | t)\hat{p}(w | t)) = \sum_{d,w} \frac{n_{dwt}}{n_t} \ln \frac{n_{dwt} n_t}{n_{dt} n_{wt}} \quad (5)$$

Проверка гипотезы условной независимости (2) для каждой пары слово-тема (w, t) является важной задачей, имеющей большую область применения в построении и оценивании вероятностных тематических моделей. Оба распределения $\hat{p}(d | t)$ и $\hat{p}(d | w, t)$ оцениваются согласно (4) в процессе построения тематической модели.

Критерий хи-квадрат Пирсона—один из статистических тестов, применяемый для проверки согласия экспериментальных данных с теоретическим распределением. Он имеет свои границы применимости и, в частности, плохо подходит для разреженных распределений [8, 7], когда число возможных значений наблюдаемой переменной значительно превосходит число наблюдений, либо когда многие значения имеют крайне низкие, хотя и ненулевые, вероятности. В этих случаях распределение статистики хи-квадрат уже не описывается классической асимптотикой, и может зависеть от длины выборки и вида теоретического распределения.

Разреженные распределения естественным образом возникают в прикладных задачах статистического анализа текстов. В работе предлагается эффективный способ оценивания функции распределения и квантилей статистики хи-квадрат, основанный на сэмплировании Монте-Карло.

!!! ДАЛЬНЕЙШЕЕ ОПИСАНИЕ

2 Критерий согласия хи-квадрат

Пусть имеется выборка n независимых наблюдений $\{x_1, \dots, x_n\}$ случайной величины, принимающей значения из конечного множества Ω . Её эмпирическое распределение определяется как доля наблюдений x_i , равных x :

$$\hat{p}(x) = \frac{1}{n} \sum_{i=1}^n [x_i = x], \quad x \in \Omega.$$

Критерий хи-квадрат проверяет гипотезу о том, что случайная величина имеет заданное распределение $p(x)$, $x \in \Omega$. Для этого вычисляется статистика хи-квадрат:

$$X^2 = n \sum_{x \in \Omega} \frac{(\hat{p}(x) - p(x))^2}{p(x)}. \quad (6)$$




Рис. 1: Функции распределения статистики X^2 при $s = 1$, $v = 50, 500, 1000, 5000$, $n = 100$, $N = 1000$ и соответствующие функции распределения $\chi^2(v - 1)$.

Распределение статистики X^2 стремится к распределению хи-квадрат с $k = |\Omega| - 1$ степенями свободы: $X^2 \sim \chi^2(k)$. Нулевая гипотеза отвергается на уровне значимости α , если значение статистики превышает $(1 - \alpha)$ -квантиль этого распределения: $X^2 > \chi_{1-\alpha}^2(k)$.

Считается, что асимптотика хи-квадрат применима, если объём выборки $n \geq 50$ и ожидаемое число наблюдений $np(x) \geq 5$ для каждого $x \in \Omega$. В случаях *разреженных* распределений $p(x)$, когда вероятности $p(x)$ малы для многих $x \in \Omega$ или когда $|\Omega| \gg n$, второе условие может не выполняться даже на очень больших выборках [8]. Стандартная рекомендация — объединять значения $x \in \Omega$ в группы — для сильно разреженных распределений оказывается неприемлемой, так как результат существенно зависит от способа группирования, который выбирается произвольно.

В качестве иллюстрации рассмотрим распределение, называемое *законом Ципфа*:

$$p(x) = Ax^{-s}, \quad x \in \Omega = \{1, \dots, v\}, \quad (7)$$

где $A = (\sum_{x=1}^v x^{-s})^{-1}$ — нормировочный множитель, s — параметр. Этот закон неплохо описывает частоты слов в текстах на естественных языках, если за x принимать номера слов, упорядоченных по убыванию частоты. Параметр s зависит от языка и от корпуса текстов, по которому делается оценка, но в большинстве экспериментов значение s близко к 1 и находится в пределах от 0.9 до 1.2 [19, 20].

Чем больше значение параметра s и размер словаря v , тем более разрежено распределение $p(x)$. Проведём простой вычислительный эксперимент. Возьмём типичные значения параметра $s = 1$ и размера словаря $v \in \{50, 500, 1000, 5000\}$. Сгене-

ририруем $N = 1000$ выборок (искусственных текстов) длины $n = 100$ из распределения (7), и для каждой выборки вычислим значение статистики X^2 .

На рис. 1 сплошными линиями показаны эмпирические распределения статистики X^2 , пунктирными линиями — распределения $\chi^2(v - 1)$. Чем больше размер слова-ря, тем сильнее разрежено распределение $p(x)$, и тем сильнее отличаются $(1 - \alpha)$ -квантили этих распределений (при типичном значении $\alpha = 0.05$).

Таким образом, распределение хи-квадрат не может быть использовано в практических задачах анализа текстов, когда требуется проверить, является ли заданный текст $\hat{p}(x)$ случайной выборкой из корпуса текстов $p(x)$.

3 Тест на основе сэмплирования

Для разреженных распределений $p(x)$ предлагается вместо асимптотического распределения $\chi^2(k)$ статистики X^2 использовать эмпирическое распределение.

Построение теста. Генерируется N независимых выборок объёма n из заданного дискретного распределения $p(x)$. Для каждой выборки вычисляется эмпирическое распределение $\hat{p}_j(x)$, $j = 1, \dots, N$ и значение статистики X_j^2 по формуле (6). По полученным значениям X_1^2, \dots, X_N^2 строится эмпирическая функция распределения статистики

$$\hat{F}_n(X^2) = \frac{1}{N} \sum_{j=1}^N [X_j^2 < X^2]$$

и вычисляется её $(1 - \alpha)$ -квантиль $\hat{F}_{n,1-\alpha}$. Число N рекомендуется брать не менее 1000, если необходимо оценивать всю функцию распределения. Однако если оценивается только одна квантиль, N можно брать порядка нескольких десятков [7].

Применение теста. Пусть задана выборка объёма n , по которой построено эмпирическое распределение $\hat{p}(x)$ и вычислено значение статистики X^2 согласно (6). Если $X^2 > \hat{F}_{n,1-\alpha}$, то нулевая гипотеза о том, что данная выборка порождена распределением $p(x)$, отклоняется.

Рекуррентное построение теста. Как будет показано ниже, в случае разреженных распределений значение квантили $\hat{F}_{n,1-\alpha}$ может зависеть от объёма выборки n . Строить тест заново для каждой выборки довольно накладно. Поэтому предлагается рекуррентный метод, позволяющий при заданном распределении $p(x)$ вычислить квантили для всех значений n один раз, и затем быстро осуществлять проверку нулевой гипотезы для выборок различного объёма n .

В рекуррентном методе N выборок $\{x_{j1}, \dots, x_{jn}\}$ наращиваются одновременно, где $j = 1, \dots, N$ — номер выборки, $n = 1, \dots, n_{\max}$ — объём выборки. Для каждого j строится эмпирическая гистограмма $H_j(x) = np_j(x)$. При добавлении каждого нового наблюдения $\xi = x_{j,n+1}$, сэмплированного из распределения $p(x)$, обновляется гистограмма и пересчитывается значение статистики $X_{j,n+1}^2$ по значению $X_{j,n}^2$. Сэмплированные выборки не сохраняются. В процессе работы алгоритм формирует двумерный массив значений статистики $X_{j,n}^2$ и одномерный массив эмпирических гистограмм $H_j(x)$. В случае $|\Omega| \gg n_{\max}$ для хранения эмпирических гистограмм лучше использовать специальные структуры данных — разреженные векторы, не выделяющие память под нулевые значения $H_j(x)$. В таком случае расход памяти для данного

Алгоритм 3.1. Построение теста путём рекуррентного вычисления значений статистики X^2 по N одновременно растущим выборкам объёма n .

Вход: $p(x)$, N , n_{\max} , α ;

Выход: $\hat{F}_{n,1-\alpha}$ для всех $n = 1, \dots, n_{\max}$;

- 1: **для всех** $j := 1, \dots, N$
 - 2: сэмплировать первый элемент j -й выборки $\xi \sim p(x)$;
 - 3: инициализировать эмпирическую гистограмму для j -й выборки:
 $H_j(x) := [x = \xi]$ для всех $x \in \Omega$;
 - 4: инициализировать значение статистики X^2 для j -й выборки:
 $X_{j,1}^2 := 1/p(\xi) - 1$;
 - 5: **для всех** $n := 1, \dots, n_{\max} - 1$
 - 6: **для всех** $j := 1, \dots, N$
 - 7: сэмплировать $(n+1)$ -й элемент j -й выборки $\xi \sim p(x)$;
 - 8: обновить эмпирическую гистограмму для j -й выборки:
 $H_j(\xi) := H_j(\xi) + 1$;
 - 9: обновить значение статистики X^2 для j -й выборки:

$$X_{j,n+1}^2 := \frac{nX_{j,n}^2 + 1}{n+1} + \frac{2H_j(\xi) - 1}{(n+1)p(\xi)} - 2$$
;
 - 10: **для всех** $n := 1, \dots, n_{\max}$
 - 11: упорядочить $X_{1,n}^2, \dots, X_{N,n}^2$ по возрастанию;
 - 12: $\hat{F}_{n,1-\alpha} := X_{N(1-\alpha),n}^2$;
-

алгоритма составляет $O(n_{\max}N)$; вычислительная сложность $O(n_{\max}N \log N)$. Детали реализации показаны в Алгоритме 3.1.

4 Регрессионный тест

Рассмотрим частную постановку задачи: проверяется нулевая гипотеза о том, что выборка с эмпирическим распределением $\hat{p}(x)$ порождена распределением Ципфа (7) с параметром s . Будем строить распределение статистики X^2 с помощью сэмплирования и исследовать зависимость квантиля $\hat{F}_{n,1-\alpha}$ от параметров n , s и v .

На рис. 2 показана зависимость 0.95-квантиля от объёма выборки n и её интерполяция функцией $\tilde{F}_{1-\alpha}(n) = A + Bn^{-1} + Cn^{-2} + Dn^{-3} + En^{-4}$ с параметрами A, B, C, D, E .

На рис. 3 показана зависимость 0.95-квантиля от показателя s в законе Ципфа и её интерполяция функцией $\tilde{F}_{1-\alpha}(s) = F + GH^s$ с параметрами F, G, H .

На рис. 4 показана зависимости 0.95-квантиля от параметра $v = |\Omega|$ и её линейная интерполяция $\tilde{F}_{1-\alpha}(v) = I + Jv$ с параметрами I, J .

Построение регрессионного теста. Чтобы найти общий вид зависимости $\tilde{F}_{1-\alpha}(s, v, n)$, применим эмпирический подход. Сформируем обучающую выборку из 1000 троек (s, v, n) , равномерно выбранных из параллелепипеда $s \in [0.9, 1.1]$, $v \in [500, 1500]$, $n \in [50, 150]$. Для каждой тройки вычислим значение $\hat{F}_{n,0.95}$.

Для поиска нелинейной регрессионной зависимости используем алгоритм символьной регрессии MVR-composer [?, ?]. Преимущество этого алгоритма в том, что он автоматически подбирает формулу регрессии среди всевозможных супер-




Рис. 2: Зависимость 0.95-квантиля X^2 от объёма выборки n при $s = 1$, $v = 500$, $N = 1000$ и ее интерполяция.




Рис. 3: Зависимость 0.95-квантиля X^2 от параметра s при $n = 100$, $v = 500$, $N = 1000$ и ее интерполяция.




Рис. 4: Зависимость 0.95-квантиля X^2 от $v = |\Omega|$ при $s = 1$, $n = 100$, $N = 1000$ и ее интерполяция.




Рис. 5: Зависимость 0.95-квантилей, аппроксимированных моделью $\tilde{F}_{1-\alpha}^4$, от их эмпирических значений при различных s , n , v .

позиций заданного множества элементарных функций. В нашем случае MVR-composer находит следующую модель регрессии: $\tilde{F}_{1-\alpha}^1(s, v, n) = (A + Bn^{-1} + Cn^{-2} + Dn^{-3} + En^{-4})(F + GH^s)(I + Jv)$ и определяет оптимальные значения 10 параметров $A, B, C, D, E, F, G, H, I, J$. Рассмотрим также некоторые упрощения этой модели:

$$\begin{aligned}\tilde{F}_{1-\alpha}^2(s, v, n) &= A(1 + Bn^{-1} + Cn^{-2} + Dn^{-3} + En^{-4})(1 + GH^s)(1 + Jv); \\ \tilde{F}_{1-\alpha}^3(s, v, n) &= A(1 + Bn^{-c})(1 + GH^s)(1 + Jv); \\ \tilde{F}_{1-\alpha}^4(s, v, n) &= Av(1 + Bn^{-c})(1 + GH^s); \\ \tilde{F}_{1-\alpha}^5(s, v, n) &= Av(1 + GH^s); \\ \tilde{F}_{1-\alpha}^6(s, v, n) &= Av(1 + Bn^{-c}).\end{aligned}$$

Параметры этих моделей настроим с помощью функции `nlinfit` программы Matlab. Начальные приближения всех параметров положим равными 1, кроме параметра A , который инициализируем средним значением $\hat{F}_{n,1-\alpha}/v$ по всей выборке. Получим следующие значения среднеквадратичной ошибки (СКО) на обучающей и контрольной выборках из 1000 случайных троек (s, v, n) каждой:

модель	$\tilde{F}_{1-\alpha}^1$	$\tilde{F}_{1-\alpha}^2$	$\tilde{F}_{1-\alpha}^3$	$\tilde{F}_{1-\alpha}^4$	$\tilde{F}_{1-\alpha}^5$	$\tilde{F}_{1-\alpha}^6$
число параметров	10	8	6	5	3	3
СКО (обучение)	16.3	16.8	16.8	16.7	52.2	43.7
СКО (контроль)	15.8	16.1	16.0	16.0	50.9	43.8

Сравнение СКО на обучающей и контрольной выборках показывает, что переобучения нет ни в одной из моделей. Модель $\tilde{F}_{1-\alpha}^4$ представляется оптимальной по точности и числу параметров. Дальнейшее упрощение модели приводит к резкому увеличению СКО. Оптимальные значения параметров для неё: $A = 0.913$, $B = 3.98$, $c = 0.636$, $G = 0.00458$, $H = 36.8$.

На рис. 4 показан график зависимости 0.95-квантилей, аппроксимированных моделью $\tilde{F}_{0.95}^4$, от их эмпирических значений при различных s , n , v . Сплошной линией изображена «идеальная» прямая $\tilde{F} = \hat{F}$.

Таким образом, в отличие от классического критерия хи-квадрат, квантиль распределения статистики X^2 существенно зависит от объёма выборки n и от вида распределения $p(x)$, в частности, от показателя степени s в законе Ципфа, отвечающего за разреженность распределения. Построенная регрессионная модель довольно точно описывает зависимость 0.95-квантили от параметров s , n , v . Эту зависимость можно построить один раз вместо того, чтобы строить тест для каждого распределения $p(x)$. Предварительно необходимо убедиться, что распределение $p(x)$ описывается законом Ципфа и найти значение параметра s . Данное обстоятельство сужает область применимости регрессионного теста.

Анализ качества регрессионного теста. Оценим вероятности ошибок первого и второго рода предложенного регрессионного теста в эксперименте.

Ошибкой первого рода называется отклонение нулевой гипотезы при условии её истинности. Вероятность ошибки первого рода равна уровню значимости $\alpha = 0.05$. Для эксперимента сгенерируем контрольную выборку из 500 различных троек (s, v, n) , равномерно распределённых на параллелепипеде $s \in [0.9, 1.1]$, $v \in [500, 1500]$, $n \in [50, 150]$. Для каждой тройки сгенерируем 1000 выборок объёма n из распределения Ципфа $p(x)$ с параметрами v и s и вычислим значение статистики X^2 . Оценим вероятность ошибки первого рода как долю выборок, для которых нулевая гипотеза отклонялась: $X^2 > \tilde{F}_{0.95}^4(s, v, n)$. Оценка вероятности ошибки первого рода составляет 0.0496 ± 0.0141 с доверительной вероятностью 0.95.

Ошибкой второго рода называется принятие гипотезы $H_0: p(x)$ при условии истинности ее альтернативы $H_1: p'(x)$. Вероятность ошибки второго рода существенно зависит от альтернативы — чем более похожи распределения $p(x)$ и $p'(x)$, тем больше вероятность ошибки. Исследуем способность теста различать распределения, отличающиеся на небольшом числе элементов x из Ω . Выделим из множества $\Omega = \{1, \dots, v\}$ подмножество элементов с наибольшими вероятностями: $\Omega_0 = \{x: p(x) > \mu p(1)\}$ при заданном $\mu \in (0, 1)$. Построим распределение $p'(x)$ из $p(x)$ следующим образом: выберем K различных случайных элементов множества Ω_0 и их вероятности поменяем местами с вероятностями K различных случайных элементов множества $\Omega \setminus \Omega_0$.

Из полученного распределения $p'(x)$ сгенерируем выборки, для каждой построим эмпирическое распределение $\hat{p}(x)$ и вычислим статистику X^2 . Если $X^2 \leq \tilde{F}_{0.95}^4(s, v, n)$, то для данной выборки гипотеза H_0 ошибочно принимается. Долю выборок, при которых это происходит, примем в качестве оценки вероятности ошибки второго рода.




Рис. 6: Зависимость вероятности ошибки второго рода от K при $\mu = 0.01$.




Рис. 7: Зависимость вероятности ошибки второго рода от K при $\mu = 0.05$.

Для каждого K сгенерируем 200 различных троек (s, v, n) из равномерного распределения на параллелепипеде $s \in [0.9, 1.1]$, $v \in [500, 1500]$, $n \in [50, 150]$ и вычислим 200 оценок вероятности ошибки второго рода. На рис. 6 и рис. 7 показаны зависимости медианы M и доверительных границ 90%, 80%, 70% вероятности ошибки второго рода от числа перестановок K при $\mu = 0.01$ и $\mu = 0.05$. По мере увеличения K распределения $p(x)$ и $p'(x)$ все сильнее отличаются, и вероятность ошибки второго рода уменьшается. По мере увеличения μ различия становятся менее контрастными, и вероятность ошибки второго рода убывает медленнее. При $\mu = 0.01$ она становится меньше 0.1 при $K = 20$, при $\mu = 0.05$ она достигает этого значения при $K = 5$.

Отсюда, в частности, можно сделать вывод, что различные тексты, отличающиеся лишь 5 высокочастотными терминами, в среднем довольно надёжно различаются по их случайным фрагментам.

5 Вероятностные тематические модели

Чтобы оценить качество тематической модели, необходимо проверить, выполняется ли гипотеза условной независимости (1) — важнейшее базовое предположение модели (3) — для каждой пары документ–тема (d, t) . Тема t описывается распределением $\hat{p}(w | t)$. Выборка слов документа d , относящихся к теме t , согласно модели, образует эмпирическое распределение $\hat{p}(w | d, t)$. Оба распределения оцениваются согласно (4) в процессе построения тематической модели. Чтобы проверить, действительно ли данная выборка могла быть получена из распределения $\hat{p}(w | t)$, воспользуемся критерием согласия, основанным на статистике хи-квадрат (6):

$$X_{dt}^2 = n_{dt} \sum_{w: n_{wt} > 0} \frac{(\hat{p}(w | d, t) - \hat{p}(w | t))^2}{\hat{p}(w | t)}. \quad (8)$$

Число различных слов в теме может быть намного больше, чем число слов в документе. Следовательно, мы имеем дело с разреженными распределениями, к которым неприменим асимптотический критерий хи-квадрат. Поэтому будем строить статистические тесты методом сэмплирования, для каждой темы $t \in T$ отдельно.

Экспериментально установлено, что для больших корпусов текстов на естественных языках закон Ципфа или более сложные параметрические законы (например

Цифа–Мандельброта) выполняются с неплохой точностью [19, 20]. Для ускорения проверки гипотезы условной независимости предлагается двухэтапный тест. Сначала проверяется согласие каждой темы t с выбранным параметрическим законом. Если согласие есть, то строится один регрессионный тест для всех таких тем. Для каждой из остальных тем строится отдельный тест на основе сэмплирования.

6 Сэмплирование без возвращений

Проверки согласия документных эмпирических распределений $\hat{p}(w | d, t)$, $d \in D$ с распределением $\hat{p}(w | t)$, вообще говоря, не являются независимыми, поскольку имеется тождество, связывающее эти распределения друг с другом:

$$\hat{p}(w | t) = \sum_{d \in D} \hat{p}(w | d, t) \hat{p}(d | t). \quad (9)$$

Документы являются выборками без возвращений из распределения $\hat{p}(w | t)$, тогда как обычно критерии согласия предполагают выборку с возвращениями. Наличие дополнительного ограничения (9) может и не влиять на результаты тестов или влиять несущественно, особенно на коллекциях большого размера. Однако это лишь предположение, которое необходимо проверить. Для этого построим более точный тест на основе сэмплирования *без возвращений*, учитывающий, что последовательность слов, образующих тему t , разрезается на документы в пропорциях $\hat{p}(d | t)$.

Построение теста сэмплированием без возвращений. Возьмём последовательность терминов длины n_t , образующую распределение $\hat{p}(w | t)$. Сгенерируем N случайных перестановок этой последовательности. Разрежем каждую из полученных последовательностей W_j , $j = 1, \dots, N$ на «документы» — подпоследовательности терминов W_{jd} длины n_{dt} каждой, $d \in D$. По каждому «документу» W_{jd} построим эмпирическое распределение $\hat{p}_j(w | d, t)$ и вычислим значение статистики хи-квадрат X_{jd}^2 . Для каждого $d \in D$ по множеству значений статистики $X_{1d}^2, \dots, X_{Nd}^2$ построим эмпирическую функцию распределения $\hat{F}_d(X^2)$ и вычислим её $(1 - \alpha)$ -квантиль $\hat{F}_{d,1-\alpha}$. Число N рекомендуется брать не менее 1000 при типичном значении $\alpha = 0.05$.

Отметим, что в teste без возвращений квантиль строится для каждого документа d , тогда как тест с возвращениями строится для каждого значения длины документа n . Построение теста без возвращений более ресурсоёмко и требует $O(n_t N \log N)$ операций вместо $O(n_{\max} N \log N)$, где $n_{\max} = \max_{d \in D} n_{td}$.

Применение теста сэмплированием без возвращений. Проверка гипотезы условной независимости для пары документ–тема (d, t) заключается в вычислении статистики X_{dt}^2 по формуле (8) и проверке неравенства $X_{dt}^2 > \hat{F}_{d,1-\alpha}$. Если оно выполнено, то гипотеза условной независимости отвергается для данной пары (d, t) .

7 Вычислительные эксперименты

Эксперименты проводились на коллекции из $|D| = 2000$ авторефератов диссертаций на русском языке. Мощность словаря после предварительной обработки данных (лемматизации и удаления стоп-слов) составляет $|W| = 20211$ слов, длина документов от 1000 до 4000 слов. Строились две тематические модели — PLSA [10] и LDA-GS [12, 13] с помощью алгоритма, описанного в [?]. Число тем $|T| = 100$.




Рис. 8: Аппроксимация эмпирических распределений слов законом Ципфа (для двух тем, в логарифмических осях).

Выполняется ли закон Ципфа для тем? На рис. 8 показаны графики эмпирических распределений и закона Ципфа для двух из 100 тем t_1 и t_2 в модели LDA, в логарифмических осях. По горизонтальной оси откладывается логарифм номера слова, слова упорядочены по частоте. По вертикальной оси откладывается логарифм вероятности слова. Оптимальные значения параметра закона Ципфа: $s = 1.04$ для t_1 , $s = 1.28$ для t_2 . Хотя «на глаз» соответствие неплохое, особенно для t_1 , нулевая гипотеза отклоняется для обоих тем. Более того, большинство тем согласуются с законом Ципфа лишь при крайне низких уровнях значимости, меньших 0.05. Это объясняется тем, что при выборках длины n_t порядка $10^3\text{--}10^5$ критерии согласия чувствительны даже к незначительным различиям распределений, и одного параметра в законе Ципфа не достаточно для описания эмпирических распределений.

Сравнение тестов без возвращений и с возвращениями.

Для модели PLSA рассматривается одна тема из $|D_t| = 1992$ документов суммарной длины $n_t = 87026$ слов. В тестах без возвращений и с возвращениями нулевая гипотеза принимается для 1674 и 1688 документов соответственно. Решения отличаются на 22 документах из 1992. Оба теста дают примерно одинаковый результат: гипотеза условной независимости отклоняется для 15% документов.

Для модели LDA-GS рассматривается тема из $|D_t| = 1114$ документов суммарной длины $n_t = 63805$ слов. Нулевая гипотеза принимается для 1032 и 1035 документов соответственно. Решения отличаются на 7 документах из 1114. Оба теста снова дают примерно одинаковый результат: нулевая гипотеза отклоняется для 7% документов.

Таким образом, результаты тестов без возвращений и с возвращениями почти одинаковы, однако тест с возвращениями менее ресурсоёмкий.

Определение оптимального числа тем.

Тест может быть использован для определения оптимального числа тем в коллекции. Если на последней итерации алгоритма LDA-GS гипотеза условной независимости принимается для всех тем, то достигнуто оптимальное число тем. Например, на модельной коллекции $D = 500$, $W = 200$, $n_d = 120$, $T = 10$ зависимость средней доли слов, не прошедших гипотезу на уровне значимости 0.05, от задаваемого числа тем изображена на рис. 7. Видно, что при числе тем, равном или большем оптимального $T = 10$, гипотеза условной независимости не отвергается.




Рис. 9: Зависимость средней доли слов, не прошедших гипотезу, от числа тем.

8 Точный тест Фишера

Точный тест Фишера [18] используется для проверки отсутствия взаимосвязи между двумя переменными в таблице сопряженности размерности 2×2 . При этом уровень значимости вычисляется, как если бы значения на границах таблицы были известны. Например, рассматриваются данные, разделенные на две категории двумя способами, с таблицей сопряженности X :

	Столбец 1	Столбец 2	Суммы по строкам
Строка 1	a	b	$a + b$
Строка 2	c	d	$c + d$
Суммы по столбцам	$a + c$	$b + d$	$a + b + c + d = n$

Тогда вероятность получить данную таблицу сопряженности при условии истинности нулевой гипотезы об отсутствии взаимосвязи между категориями задается гипергеометрическим распределением:

$$P(X) = \frac{C_{a+b}^a C_{c+d}^c}{C_n^{a+c}} = \frac{(a+b)! (c+d)! (a+c)! (b+d)!}{a! b! c! d! n!}, \quad (10)$$

где C_n^k —биномиальный коэффициент, $(a+b)$ и $(c+d)$ —маргинальные суммы по строкам, $(a+c)$ и $(b+d)$ —по столбцам, n —общее число наблюдений. Уровень значимости для двустороннего варианта теста Фишера:

$$\text{Pvalue}_2 = \sum_{Y: P(Y) \leq P(X)} P(Y),$$

где Y —всевозможные таблицы сопряженности с той же суммой элементов в каждой строке и каждом столбце, что и в таблице X . Для проверки гипотезы против односторонней альтернативы о том, что наблюдения из строки 1 чаще попадают в столбец 1, чем в столбец 2, уровень значимости вычисляется по формуле:

$$\text{Pvalue}_1 = \sum_Z P(Z), \quad (11)$$

где Z —таблицы сопряженности с теми же маргинальными суммами, что и X , но обладающие не меньшими элементами первой строки первого столбца, чем X . Другими

Алгоритм 9.1. Односторонний тест Фишера

```

1: ПРОЦЕДУРА Fisher( $X$ )
2:  $r = \text{rand}(0,1)$ 
3:  $P\text{value} = \sum_{Z \neq X} P(Z) + rP(X)$ 
4: return  $P\text{value}$ 

```

словами, таблицы Z имеют вид:

	Столбец 1	Столбец 2	Суммы по строкам
Строка 1	a'	b'	$a' + b'$
Строка 2	c'	d'	$c' + d'$
Суммы по столбцам	$a' + c'$	$b' + d'$	$a' + b' + c' + d' = n'$

Причем выполняется:

$$\begin{cases} a' \geq a \\ a' + b' = a + b \\ c' + d' = c + d \\ a' + c' = a + c \\ b' + d' = b + d \\ n' = n \end{cases} \quad (12)$$

В случае больших выборок используется тест хи-квадрат, но он неприменим, когда математические ожидания значений в любой из ячеек таблицы с заданными границами ниже 10. Дело в том, что приближение выборочного распределения испытуемой статистической величины распределением хи-квадрат оказывается неадекватным при неравнозначенном распределении данных среди ячеек таблицы, а также при малых размерах выборки. В таких случаях применяется точный тест Фишера, который не зависит от особенностей выборки.

9 Применение точного теста Фишера для проверки гипотезы условной независимости

Проверка гипотезы для фиксированной тройки (d, w, t) . Для каждого слова $w \in W$ и документа $d \in D$ в фиксированной теме $t \in T$ предлагается выполнить проверку гипотезы об их независимости с помощью точного теста Фишера. Таблица сопряженности для рассматриваемой тройки (d, w, t) имеет вид:

	w	$W \setminus w$	Суммы по строкам
d	n_{dwt}	$n_{dt} - n_{dwt}$	n_{dt}
$D \setminus d$	$n_{wt} - n_{dwt}$	$n_t - n_{dt} - n_{wt} + n_{dwt}$	$n_t - n_{dt}$
Суммы по столбцам	n_{wt}	$n_t - n_{wt}$	n_t

При анализе текстов математическое ожидание числа наблюдений в первом ячейке таблицы обычно оказывается меньше 10, поэтому асимптотика хи-квадрат неприменима. Рассматривается односторонняя альтернатива, заключающаяся в том, что слово w из темы t слишком часто встречается в документе d . При этом уровень значимости вычисляется по формуле (11) и может принимать лишь дискретный набор

Алгоритм 9.2. Проверка гипотезы условной независимости для темы t

Вход: $t, n_t, \alpha, n_{dwt}, n_{dt}, n_{wt} \forall d \in D, w \in W;$

Выход: принять или отклонить гипотезу на уровне значимости α ;

- 1: **для всех** документов $d \in D$
 - 2: **для всех** слов $w \in W$
 - 3: **если** $n_{dt} > 0$ и $n_{wt} > 0$ **то**
 - 4: проверить независимость d и w в теме t :
составить таблицу сопряженности X_{dwt} :

	w	$W \setminus w$
d	n_{dwt}	$n_{dt} - n_{dwt}$
$D \setminus d$	$n_{wt} - n_{dwt}$	$n_t - n_{dt} - n_{wt} + n_{dwt}$
 - 5: проводить точный тест Фишера и получить рандомизированное значение уровня значимости:
 $Pvalue_{dwt} = Fisher(X_{dwt})$
 - 6: проверить гипотезу о равномерности распределения $Pvalue_{dwt}$
на уровне значимости α с помощью критерия Пирсона:
-

значений. Для того, чтобы избежать дискретности, предлагается вычислять уровень значимости следующим образом:

$$Pvalue_{rand} = \sum_{Z \neq X} P(Z) + rP(X), \quad (13)$$

где суммирование вероятностей производится для таблиц сопряженности Z , не совпадающих с X и обладающих свойством (12), r —случайная величина из равномерного распределения на отрезке $[0,1]$ (Процедура 9.1).

МОЖНО ПРОИЛЮСТРИРОВАТЬ НА КАРТИНКЕ

Проверка гипотезы условной независимости для темы t . Для того, чтобы определить, описывает ли тематическая модель данную тему t , предлагается алгоритм 9.2. Проверка гипотезы условной независимости слов в теме от документов сводится к проверке гипотез о независимости каждого слова от каждого документа в теме. Другими словами, для каждой пары (d,w) с $n_{dt} > 0$ и $n_{wt} > 0$ (принадлежащих теме) проводится точный тест Фишера, описанный выше. В условиях истинности нулевой гипотезы, распределение вычисленных уровней значимости $Pvalue_{dwt}$ должно быть близко к равномерному, что проверяется с помощью критерия согласия Пирсона.

Список литературы

- [1] L. Fei-Fei and P. Perona *A Bayesian hierarchical model for learning natural scene categories*, IEEE Computer Vision and Pattern Recognition, pages 524-531, 2005.
- [2] D.Blei and M.Jordan *Modelling annotated data* In Proceedings of the 26th annual International ACM SIGIR Conference on Research and Development in Information Retrieval, pages 127-134. ACM Press, 2003.
- [3] E.Bart, M.Welling, and P. Perona *Unsupervised organization of image collections: Taxonomies and beyond*, Transactions on Pattern Recognition and Machine Intelligence, 2010.
- [4] J.Li, C.Wang, Y.Lim, D.Blei, and L.Fei-Fei *Building and using a semantivisual image hierarchy*, In Computer Vision and Pattern Recognition, 2010.
- [5] S.Deerwester; S. T. Dumais; T. K. Landauer; G. W. Furnas and R. A. Harshman *Indexing by latent semantic analysis*, Journal of the Society for Information Science, 41(6), 391-407, 1990.
- [6] Papadimitriou, Christos; Raghavan, Prabhakar; Tamaki, Hisao; Vempala, Santosh *Latent Semantic Indexing: A probabilistic analysis*, Proceedings of ACM PODS, 1998.
- [7] von Davier M. *Bootstrapping goodness-of-fit statistics for sparse categorical data-results of a monte carlo study*, Methods of Psychological Research Online,1997.
- [8] Zelterman D. *Goodness-of-fit tests for large sparse multinomial distributions*, Journal of the American Statistical Association, Pp. 624-629, 1987.
- [9] Daud, Ali and Li, Juanzi and Zhou, Lizhu and Muhammad, Faqir *Knowledge discovery through directed probabilistic topic models: a survey*, Frontiers of Computer Science in China,Pp. 280-301, 2010.
- [10] Hofmann, Thomas *Probabilistic latent semantic indexing*,Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval, Pp.50-57,1999.
- [11] Dempster A.P., Laird N. M., Rubin D. B. *Maximum likelihood from incomplete data via the EM algorithm*, J. of the Royal Statistical Society, Series B., no.34, Pp.1-38, 1977.
- [12] Blei, David M. and Ng, Andrew Y. and Jordan, Michael I. *Latent Dirichlet allocation*, Journal of Machine Learning Research, Pp.993-1022, 2003.
- [13] Steyvers, Mark and Griffiths, Tom, *Finding scientific topics* ,Proceedings of the National Academy of Sciences, Pp.5228-5235, 2004.
- [14] A. Asuncion and M. Welling and P. Smyth and Y. W. Teh, *On Smoothing and Inference for Topic Models*, Proceedings of the International Conference on Uncertainty in Artificial Intelligence, 2009.

- [15] Yi Wang, *Distributed Gibbs Sampling of Latent Dirichlet Allocation: The Gritty Details*, 2008.
- [16] G.Golub and C.Reinsch, *Handbook for matrix computation II, Linear Algebra*, Springer-Verlag, New York, 1971.
- [17] Mimno D., Blei D., *Bayesian checking for topic models*, 11th Conference on Empirical Methods in Natural Language Processing.— Association for Computational Linguistics, 2011.—Pp. 227-237.
- [18] Fisher, R. A. *On the interpretation of χ^2 from contingency tables, and the calculation of P*, Journal of the Royal Statistical Society, 1922 85(1):87-94.
- [19] Бриллюэн Л. *Наука и теория информации*, М.: «Государственное издательство физико-математической литературы», 1960.—391c.
- [20] Gelbukh A., Sidorov G. *Zipf and heaps laws' coefficients depend on language* //Proc. CICLing-2001, Conference on Intelligent Text Processing and Computational Linguistics, February 18–24, 2001, Mexico City, Lecture Notes in Computer Science.— No. 2004.— Springer-Verlag, 2001.—P. 332–335.