


Ю.Н. Орлов

Институт прикладной математики им. М.В. Келдыша РАН,
кафедра высшей математики МФТИ

Методы статистического анализа
литературных текстов



Обсуждаемые вопросы



- Точность статистического анализа в зависимости от объема текста.
- Идентификация автора неизвестного текста в библиотеке эталонов, создание эталонов и кластеризация текстов.
- Оператор трансляций распределения текста по буквам и спектральные портреты. Эффект переводчика.

Обсуждаемые вопросы



- Анализ авторских tandemов и проверка текста на однородность. Динамические системы, генерирующие ряд расстояний между одинаковыми буквами в тексте.
- Анализ европейских языков. Функция распределения букв по частоте встречаемости. Фонетический анализ алфавитов по избыточности или недостаточности символов.

Цель и программа работы



- Сопоставление тексту структуры в фазовом пространстве (букв, слов и т.п.)
- Введение нормы как расстояния между структурами в фазовом пространстве
- Определение проекторов на подпространства с целью классификации: языка текста, эпохи написания, типа (проза или поэзия), формата (роман, очерк, эссе), жанра (детектив, триллер), автора

Текстовый инвариант? – Нет!



- Текстовый инвариант – это функционал $F(T)$ от текстовой структуры. Два текста близки в фазовом пространстве, если близки функционалы:

$$|F(T_1) - F(T_2)| < \varepsilon$$

- Цель работы – ввести наилучшим образом расстояние в пространстве структур

,

т.е. рассматривать не разность функционалов, а функционал разности.




1. Статистическая достоверность определения частот употребления букв в литературных произведениях

Выборочное распределение текста по буквам



- Пусть ξ – случайная величина (буква или буквосочетание), принимающая значения из конечного упорядоченного множества букв (пар букв, и т.д.) в алфавите.
- 1-ВПФР $f_{1N}(i)$ есть эмпирическая вероятность обнаружения данной (i -ой) буквы в тексте из N символов, 2-ВПФР $f_{2N}(i,j)$ – пары букв, и т.д.
- «Время» – это порядковый номер буквы в тексте. Пробелы и знаки игнорируются.

Стационарный критерий однородности выборки



- *Критерий Колмогорова-Смирнова*

Пусть $F_1(n, x)$ и $F_2(n, x)$ – эмпирические функции распределения, построенные по двум независимым наборам из n испытаний для процесса, имеющего некоторую стационарную непрерывную функцию распределения. Пусть также $D_n = \sup_x |F_1(n, x) - F_2(n, x)|$.

Тогда


$$\lim_{n \rightarrow \infty} P\left\{ \sqrt{\frac{n}{2}} D_n < z \right\} = K(z) = \sum_{k=-\infty}^{\infty} (-1)^k \exp\left(-2k^2 z^2\right)$$

Согласованный уровень стационарности



- Вероятность того, что отклонение D больше ε , равна ε :

$$D = 1 - K\left(\sqrt{\frac{n}{2}}D\right)$$



Стационарно объясняемая доля отклонений между 1-ВПФР



- Пусть $G(D)$ есть эмпирическая плотность распределения статистики D . Тогда доля ε -стационарно объясняемых отклонений равна

$$\eta(n) = \int_0^{\varepsilon(n)} G(D)dD = 1 - \varepsilon(n)?$$

Объем	Стационарная оценка вероятности малых отклонений	Факт
1000	0,94	0,05
10 000	0,98	0,08
50 000	0,99	0,10
100 000	0,995	0,15

Уровень нестационарности текстов




- Расстояние между ПФР текстов:

$$\rho_{12} = \left\| f^{(1)} - f^{(2)} \right\| = \sum_{i=1}^n \left| f_{N_1}^{(1)}(i) - f_{N_2}^{(2)}(i) \right|$$

- Чтобы сравнивать распределения текстов разных объемов, следует убедиться в том, что каждый из них стабилизируется:


$$\exists L(\varepsilon): \forall N_1, N_2 \geq L(\varepsilon) \quad \sum_{i=1}^n \left| f_{N_1}(i) - f_{N_2}(i) \right| \leq \varepsilon$$

Длина квазистационарности $L(\varepsilon)$ для 1-ПФР



Для практических целей, где допустимы небольшие отклонения 1-ПФР отрывка от 1-ПФР всего текста, достаточно сравнительно небольших объемов текстов.

На какой части текста достигается ε -стационарность?



Для подавляющего большинства текстов уровень 0,05-стационарности достигается на объемах, меньших 30% текста.

Оценка минимально достаточной длины текста



- Предположим, что буквы образуют стационарный ряд. Медианное значение частоты равно $f = 0,056$.
- Оценка объема текста для построения распределения с точностью ε :

$$N(\varepsilon) > \frac{1}{f} \left(\frac{t_{1-\varepsilon}}{\varepsilon} \right)^2$$

- При $\varepsilon=0,05$ получается $N=30$ тыс. знаков



2. Кластеризация текстов, создание эталонных распределений и метод идентификации автора

Идентификация автора текста




Пусть имеется библиотека из A авторов, у a -го автора K_a текстов, в i -ом тексте $N_{i,a}$ знаков, и $f_{i,a}(j)$ есть ПФР отдельного текста. Вводится эталонная ПФР автора:

$$f_a(j) = \frac{1}{N_a} \sum_{i=1}^{K_a} f_{i,a}(j) N_{i,a}, \quad N_a = \sum_{i=1}^{K_a} N_{i,a}.$$

Пусть $f_0(j)$ - ПФР текста неизвестного автора. Автор определяется по правилу

$$\rho_a^0 = \|f_0 - f_a\|, \quad a^0 = \arg \min_a \rho_a^0$$

Авторские 1-ПФР




- Вывод: авторские 1-ПФР очень близки, поэтому различие между ними должно выявляться на «тонкой структуре» их взаимных различий, а не функционала от них как таковых


Распределение расстояний между 2-ПФР в норме L1




$$\rho_{a,b} = \|f_a - f_b\|_{L1} = \sum_j |f_a(j) - f_b(j)|$$



Распределение расстояний между 2-ПФР в норме KL



$$\rho_{a,b} = \|f_a - f_b\|_{KL} = \sum_j f_a(j) \ln \left(\frac{f_a(j)}{f_b(j)} \right)$$



Ошибки 1-го и 2-го родов



$F_a^+(\rho)$ функция распределения расстояний текстов автора от его эталона;

$F_a^-(\rho)$ чужих текстов от него же;

$$\rho_a^+ : \min \rho, F_a^+(\rho) = 1; \quad \rho_a^- : \max \rho, F_a^-(\rho) = 0$$

$F_a^-(\rho_a^+)$ есть вероятность ошибочно отклонить текст автора, посчитав его чужим (ошибка 1-го рода);

$1 - F_a^+(\rho_a^-)$ есть вероятность ошибочно признать чужой текст авторским (ошибка 2-го рода)

Мощность статистических методов идентификации автора



1000 текстов, 100 авторов	Ошибка, %
Близость 2-ПФР в норме KL	1
Близость 2-ПФР в норме L1	4
Близость вектора «подсознания» в норме L1	12
Близость 1-ПФР в норме L1	15
Доля служебных слов	68
Информационная энтропия 2-ПФР	71
Доля гласных	81
Среднее число слов в предложении	87



3. Спектральные портреты авторов и эффект переводчика


Оператор трансляций



- Пусть $P_{ij}(l)$ есть условная вероятность того, что буква j отстоит от буквы i на $l-1$ символов.
- Пусть также $K_i(t)$ есть i -ая компонента вектора вероятностей того, что буква i реализуется в тексте в момент t .
- Тогда

$$\mathbf{K}(t + l) = P(l)\mathbf{K}(t)$$

Оператор трансляций на 1 шаг



- $P_{ij}(1)$ выражается через 1-ПФР и 2-ПФР:

$$P_{jk}(1) = F(k, j) / f(k)$$

- По формуле полной вероятности

$$f(j) = \sum_k F(k, j) = \sum_k P_{jk}(1) f(k)$$

- Следовательно, 1-ПФР

$$f(j) = \sum_k F(k, j)$$

является с.в. оператора $P_{jk}(1)$, отвечающим с.з. 1.

ε -спектр оператора соседних трансляций



- Число λ называется принадлежащим ε -спектру $\Lambda_\varepsilon(P)$ матрицы P , если существует матрица Δ такая, что

$$\|\Delta\| \leq \varepsilon \|P\| \quad \det(\lambda E - P - \Delta) = 0$$

- Резольвентой матрицы P называется матрица

$$R(\lambda) = (\lambda I - P)^{-1}$$

Тогда $\lambda \in \Lambda_\varepsilon(P)$ если $\|R(\lambda)\| \geq \frac{1}{\varepsilon \|P\|}$

Вычисление ε -спектра




- Параметром дихотомии спектра относительно кривой γ называется норма квадрата резольвенты на данной кривой:

$$\kappa_\gamma(P) = \frac{\|P\|^2}{2\pi r} \oint_{\gamma} \|R(\lambda)\|^2 d\lambda, \quad \gamma : \lambda = re^{i\phi}$$


Если на кривой нет точек спектра, то норма резольвенты на этой кривой конечна.

- Спектральные портреты операторов P для разных авторов показывают устойчивость этой структуры для текстов одного автора и различающиеся картины для разных авторов.


Примеры спектральных портретов писателей




Примеры спектральных портретов писателей




Примеры спектральных портретов писателей



Примеры спектральных портретов писателей



Примеры спектральных портретов писателей





Эффект переводчика и вектор «подсознания»




- Кроме с.з. λ_1 , которому отвечает с.в. 1-ПФР f , у оператора $P(1)$ еще одно устойчивое с.з. $\mu \approx -0,56$. Ему отвечает правый с.в. S и левый S^* .
- Оказалось, что (S^*, f) , т.е. векторы S^* и f приближенно образуют главные направления оператора трансляций.
- Вектор S , как и вектор 1-ПФР f , весьма точно идентифицирует автора. Однако в переводах это идентификационное свойство теряется.
- Вывод: изложение можно отличить от сочинения, а переводчик не является соавтором.

Шекспир – оригинальный текст





«Гамлет»




«Много
шума из
ничего»

Шекспир – перевод



«Гамлет»
(Лозинский)



«Много
шума из
ничего»
(Щепкина-
Куперник)



4. Анализ авторских tandemов и проверка текста на однородность

Горизонтальный ряд



- Пусть $x(t)$ – эквидистантный временной ряд, $f(N,t)$ – его ВПФР, построенная к моменту t по выборке объема N .
- Горизонтальным рядом $h(t,\tau ;\varepsilon)$ для ряда $x(t)$ называется минимальный объем выборки такой, что


$$\forall N \geq h(t,\tau ;\varepsilon), \quad \forall k \in [0;\tau]: \quad \|f(N,t+k) - f(N,t)\| \leq \varepsilon$$

$$h_{\max} = \min\{2; [2\tau / \varepsilon]\}$$

Примеры горизонтных рядов



Равномерно распределенный БШ



Сдвиг ВПФР
на $\tau = 10$
при уровне
 $\varepsilon = 0,05$

Логистическая ХДС




Значения h ,
близкие к
предельным,
означают
хаос, а
уменьшение
означает
взаимосвязь
элементов


Горизонтальный ряд как индикатор разладки ($\tau = 10$, $\varepsilon = 0,05$)





Нестационарный ряд CLO



Распределения горизонтных рядов для $\tau = 10$, $\varepsilon = 0,05$



Распределение расстояний между одинаковыми буквами



$$\ln l_{i,\max} \approx 0,2 \exp\left(\frac{2}{f(i)}\right)$$

$$B_i(l) = \frac{(\lambda_i l)^{\gamma_i} i}{\Gamma(\gamma_i + 1)} e^{-\lambda_i l}$$

$$\lambda_i \approx \frac{1}{4 + \frac{1}{f(i)} + \frac{5}{2} \ln f(i)},$$

$$\gamma_i = \frac{\lambda_i}{f(i)} - 1 \approx 1/4$$

Распределение горизонтного ряда для расстояний «b-b» ($\tau = 10$, $\varepsilon = 0,05$)




Для всех букв распределение горизонтного ряда
одинаково. Оно похоже на распределение для
нелинейно коррелированных многомерных ХДС.


Горизонтные ряды расстояний между гласными дляmono и тандема



тандем (Стругацкие)



моно (Тургенев)





У mono-писателей горизонтный ряд не достигает последней полосы шириной в горизонт, а у тандемов есть места максимальных рассогласований




5. Упорядоченность букв по частоте встречаемости в европейских языках

Расстояния между текстами при различном упорядочении




Распределение букв по частоте в алфавите из $n=32$ знаков



- С детерминацией 0,97

$$f(k) = a - b \ln(k)$$



Ранг буквы	Гоголь	Достоевский	Толстой	Тургенев
1	О	О	О	О
2	Е	Е	А	Е
3	А	А	Е	А
4	И	И	И	Н
5	Т	Н	Н	И
6	Н	Т	Т	Т


Распределение букв по частоте в текстах на русском языке



Минимальная
интегральная
ошибка
приближения,
равная 0,05,
получается при
 $o=0$ в модели:

$$f(k) = \frac{1}{n} \left(1 + \frac{1}{n+o} \ln \frac{n!}{k^n} \right),$$

$$o = \text{const} = 0$$



- Эта зависимость выполнена и для старославянских текстов ($n=43$), и для русской литературы XIX века ($n=37$). Для русских текстов в транслите ($n=23$ символа) $o=+9$.


Избыточность и недостаточность алфавитов европейских языков




- Параметр o трактуем как оценку избыточности ($o < 0$) или недостаточности ($o > 0$) алфавита по отношению к звуковому ряду. В текстах на всех языках без огласовки $n = 20$, $o = 0$.

Языки	Число символов	Параметры оптимальной модели
Русский	$n=33$	$n=32, o= 0$
Болгарский	$n=30$	$n=30, o= -4$
Чешский	$n=42$	$n=30, o= +1$
Польский	$n=32$	$n=32, o= +3$
Шведский	$n=29$	$n=25, o= +1$
Датский	$n=29$	$n=28, o= -5$
Немецкий	$n=30$	$n=26, o= -4$
Английский	$n=26$	$n=26, o= 0$
Итальянский	$n=26$	$n=26, o= -4$
Испанский	$n=27$	$n=26, o= -4$
Французский	$n=42$	$n=26, o= -4$

Основные результаты



- 2-ПФР представляет ту текстовую структуру, расстояние в которой позволяет с высокой точностью опознавать автора
- Построен индикатор однородности текста (горизонтный ряд), позволяющий анализировать небольшие фрагменты на предмет количества возможных соавторов
- Изучен спектр оператора эволюции 1-ПФР и показана авторская устойчивость спектральных портретов. Пара главных направлений позволяет определить, собственный ли это текст автора, или изложение чужих мыслей
- Найдено универсальное полуэмпирическое распределение букв по частоте встречаемости в европейских языках, позволяющее оценить фонетическую адекватность алфавита



СПАСИБО ЗА ВНИМАНИЕ