



НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
УНИВЕРСИТЕТ

Факультет гуманитарных наук НИУ ВШЭ – Нижний
Новгород

МОДЕЛИРОВАНИЕ ЯЗЫКОВОЙ ЛИЧНОСТИ АВТОРА ПИСЬМЕННОГО ТЕКСТА С ПОМОЩЬЮ МЕТОДОВ ТЕКСТОМАЙНИНГА И МОДЕЛЬНОЙ ЛИНГВИСТИКИ

Нижний Новгород, 2020

Грант РФФИ в рамках научного проекта № 19-31-27001 "Аспиранты" (№ 19-312-90022)



Атрибуция (от лат. *attributio* - приписывание) – это установление принадлежности анонимного художественного произведения определенному автору, местной или национальной художественной школе, а также определение времени его создания [Популярная художественная энциклопедия 1986, URL: <https://rus-pictures-enc.slovaronline.com/285-Атрибуция> (дата обращения 07.10.2018 г.)].

Автором текста считается «создатель какого-нибудь произведения» [Толковый словарь русского языка, 1994, URL: <http://www.slovopedia.com/4/192/640227.html> (дата обращения 07.10.2018 г.)]. Автор обладает основной для атрибуции именно его текстов особенностью – идиостилем, или индивидуальным стилем.

Идиостиль – «совокупность языковых и стилистико-текстовых особенностей, свойственных речи писателя, ученого, публициста, а также отдельных носителей данного языка» [Стилистический энциклопедический словарь русского языка, 2011: 95].



СОВРЕМЕННОЕ СОСТОЯНИЕ

Квантитативный подход	Качественный анализ текста
<ul style="list-style-type: none">- программы и алгоритмы атрибуционного анализа;- по количественному анализу лексических составляющих текста;- по количественному анализу синтаксических составляющих текста;- по классическим статистическим параметрам текста (текстовые длины: слов, предложений; количества: слов, предложений и пр.);	<ul style="list-style-type: none">- идиостиль (набор авторски маркированных речевых характеристик на всех уровнях языка);- речевые компетенции (авторский речевой потенциал: не только то, что автор сказал, но и то, что он может сказать);- психотипы (по Валерию Павловичу Белянинну: светлые, темные, активные и пр. тексты);



ПОЧЕМУ ИНТЕГРАЦИЯ?

стилеметрия

- Л. Кэмпбелл [Campbell 1867] и В. Лютославский [Lutoslawski 1897] на западе и Н.А. Морозова [Морозов 1916] в России
- [Mendenhall 1887, Mosteller, Wallace 1964, Захаров 2000, Merriam 2003, Labbe, Labbe, 2001, Juola, Sofko, Brennan 2006, Мартыненко 2015, Litvinova, Seredin, Litvinova, etc., 2017, Wright 2017, Karlgren, Esposito, Gratton, etc. 2018, и пр.]

кваликативные исследования

- [Вул 1973, 2007; Горошко 2003, Комиссаров 2001, McMenamin 2002, Галяшина 2003, Coulthard 2004 и пр.]

- объяснение длины предложения [Степаненко 2017:19-20];
- объяснение n-грамм [Захаров, Хохлова 2008: 41-42];
- исследования глубинных синтаксических структур [Марусенко 1990; Родионова 2008 и пр.].

ПОЧЕМУ ИНТЕГРАЦИЯ?

▪ Идея

- интеграции анализа традиционных стилостатистических параметров (длин слов и предложений, наиболее частотных n-грамм, служебных слов и POS-tags) и анализа авторских идиосинкразем, в основном ошибок разного рода, предложенный [Koppel, Schler 2003]

▪ **Необходимость**

Междисциплинарность в науке

Нужды прикладных областей знания
(судебное автороведение):

законодательство [Приказ от 27 декабря
2012 года N 237; Федеральный закон от 31 мая
2001 г. N 73-ФЗ];

методика [Рубцова, Ермолаева, Безрукова и
др. 2007]



НЕОБХОДИМОСТЬ - ИНТЕГРАЦИЯ КОЛИЧЕСТВЕННОГО И КАЧЕСТВЕННОГО ПОДХОДОВ

- 1) **Баранов** А.Н. Введение в прикладную лингвистику: Учебное пособие. — М.: Эдиториал УРСС, 2001. — 360 с.
- 2) **Koppel**, M., **Schler**, J. (2003). Exploiting Stylistic Idiosyncrasies for Authorship Attribution. Proceedings of IJCAI'03 Workshop on Computational Approaches to Style Analysis and Synthesis, 69, 72-80.
- 3) Хоменко А. Ю. Алгоритм для автоматической идентификации автора письменного речевого произведения в судебном автороведении // Юрислингвистика. 2014. № 3. С. 83-93.
- 4) Хоменко А. Ю. Атрибуция текстов малого объёма. Статистические закономерности. Язык. Право. Общество: сб. ст. V Междунар. науч.-практ. конф. Пенза : ПГУ, 2018. С. 123-127.
- 5) Хоменко А. Ю. К вопросу об исследовании письменного речевого произведения в рамках автороведческой экспертизы на предмет его оригинальности // Политическая лингвистика. 2014. № 4. С. 306-312.
- 6) Хоменко А. Ю. Лингвистическая атрибуционная экспертиза в отечественной и зарубежной школах. перспективы развития автороведческих методик в России. Международная научная конференция «Современная теоретическая лингвистика и проблемы судебной экспертизы». М. : Государственный институт русского языка им. А.С. Пушкина, 2019. С. 536-550.
- 7) Хоменко А. Ю. Лингвистическое атрибуционное исследование коротких письменных текстов: качественные и количественные методы // Политическая лингвистика. 2019. № 2 (74). С. 177-187.
- 8) Хоменко А. Ю. Лингвистическое моделирование как инструмент выявления искажений речевых навыков автора письменного речевого произведения. Опыт практического исследования // Вопросы психолингвистики. 2018. № 2 (36). С. 209-226.
- 9) Хоменко А. Ю. Моделирование когнитивных структур на основе методик автороведческого анализа. Когнитивные исследования языка. Вып. XXXVII: Интегративные процессы в когнитивной лингвистике: материалы международного конгресса по когнитивной лингвистике / Отв. ред.: Т. В. Романова. Т. XXXVII: Интегративные процессы в когнитивной лингвистике: материалы международного конгресса по когнитивной лингвистике. Деком, 2019. С. 1069-1074.
- 10) **Pimonova** E., **Durandin** O., **Malafeev** A. Doc2vec or better interpretability? a method study for authorship attribution Paper presented at Dialogue 2020, Moscow, June 15–20, 2020. <http://www.dialog-21.ru/media/4955/pimonovaeplusetal-132.pdf> (2020) (дата обращения: 05.08.2020 г.).



ИНТЕГРАТИВНАЯ МЕТОДИКА, ИМЕЮЩАЯ СЛЕДУЮЩИЕ ИТЕРАЦИИ

- 1) автоматическое извлечение из текста параметров, описывающих идиостиль с точки зрения прагматикона, тезауруса и лексикона автора;
- 2) поиск традиционных стилеметрических текстовых данных;
- 3) присвоение веса каждому параметру;
- 4) построение математических моделей сравниваемых текстов;
- 5) сравнение математических моделей с целью выявления уровня их корреляции между собой.



МЕТОДИКО-МЕТОДОЛОГИЧЕСКАЯ БАЗА

- 1) методы когнитивной лингвистики и психолингвистики, как то: анализ языковой личности автора письменного текста по методике Ю.Н. Караулова, анализ компетенций языковой личности по методике С.М. Вула и Е.С. Горошко;
- 2) традиционный структуралистский подход к языку как уровневой системе (с применением морфологического, словообразовательного, лексического, синтаксического, семантического анализов);
- 3) компьютерные методы анализа речевых структур (преимущественно автоматическая обработка текстов с целью вычленения идентификационных параметров)

Основным инструментом исследования стал язык программирования «Python».



ГИПОТЕЗА ИССЛЕДОВАНИЯ

Интегративная атрибуционная модель, получаемая в результате ряда итераций, способна успешно решать идентификационную задачу атрибуционной лингвистики на текстах любого объема.



Методики атрибуции становятся необходимыми:

- 1) в филологических экспертизах при определении авторства известных художественных произведений (статьи Ф.М.Достоевского, работы М.А.Шолохова);
- 2) в судебных автороведческих экспертизах при решении диагностических и идентификационных задач, при анализе контента сети Интернет на предмет автоматического поиска содержания деликтной направленности;
- 3) при решении научных задач, связанных с идентификацией лиц по письменной речи и определением характеристик пола, возраста, социального статуса этих лиц.



ПЕРВЫЙ ЭТАП РАБОТЫ

[Campbell 1867], [Lutoslawski 1897], [Морозов 1916], [Mendenhall 1887, Mosteller, Wallace 1964, Захаров 2000, , Merriam 2003, Labbe, Labbe, 2001, Juola, Sofko, Brennan 2006, Мартыненко 2015, Litvinova, Seredin, Litvinova, etc., 2017, Wright 2017, Karlgren, Esposito, Gratton, etc. 2018, и пр.], [Вул 1973, 2007; Горошко 2003, Комиссаров 2001, McMenamin 2002, Галяшина 2003, Coulthard 2004 и пр.], [Степаненко 2017:19-20], [Захаров, Хохлова 2008: 41-42], [Марусенко 1990; Родионова 2008 и пр.], [Koppel, Schler 2003], [Баранов 2001: 43–52; Хоменко 2013; 2014а,б,в, 2018, 2019а,б,в, г, 2020; Pimonova, Durandin, Malafeev 2020] и пр.

Ежегодная международная конференция «Диалог» (URL: <http://www.dialog-21.ru/>); Международная конференция «AINL: Artificial Intelligence and Natural Language Conference» (URL: <https://ainlconf.ru/>); Международная конференция «International Conference on Analysis of Images, Social Networks and Texts» (URL: <https://aistconf.org/>); серия мероприятий «PAN» в рамках «Conference and Labs of the Evaluation Forum, или Cross-Language Evaluation Forum», (URL: <https://pan.webis.de/>):

[Bacciu, Morgia, La 2019], [Litvinova, Sboev, Panicheva 2018], [Custódio, Paraboni 2018], [Murauer, Tschuggnall, Specht 2018], [Muttenthaler, Lucas, Amann 2019], [Litvinova, Sboev, Panicheva 2018], [Custódio, Paraboni 2018], [Panicheva, Mirzagitova, Ledovaya 2018], [Gomzin, Laguta, Stroev 2018], [Korobov 2015], [Bacciu, Morgia, La 2019].



Архитектура модели

реализация прагматикона личности на синтаксическом уровне	описание тезауруса личности	вербально-семантический уровень авторского лексикона
<p>вводные слова и конструкции, эксплицирующие субъективную модальность; целевые, выделительные и сравнительные обороты, репрезентирующие уровень освоения автором компетенций письменной речи и его отношение к действительности; синтаксические сращения, дающие представление в том числе о функциональной стилистической отнесенности текста; сравнительные придаточные, глагольные односоставные предложения, эксплицирующие репрезентацию действительности в текстовом материале; обращения;</p>	<p>наиболее частотные сочетания слов, которые описывают грамматико-семантические особенности текста; ключевые лексемы текста; экспликаты аксиологических текстовых доминант дихотомии «свой/чужой»;</p> <p>Пример формализованного правила: экспликаты субъективной модальности (вводные слова): 1) __, Prnt, __ 2) <начало предложения> Prnt, __ со списком вводных слов</p>	<p>частеречная отнесенность слов текста (количество глаголов, прилагательных, существительных и пр. частей речи), сложные слова полуслитного написания; модальные частицы, междометия, наличие/отсутствие модального постфикса «-то», предпочтительные слова-интенсификаторы.</p>



Архитектура прототипа ПО

Стилостатистика

- ✓ Индекс удобочитаемости Флеша-Кинкейда
- ✓ Индекс туманности Ганнинга
- ✓ Средняя длина слова (в буквах)
- ✓ Средняя длина предложения (в словах)
- ✓ Количество предложений длиннее 8-ми слов
- ✓ Коэффициент предметности (Pr)
- ✓ Коэффициент качества (Qu)
- ✓ Коэффициент активности (Ac)
- ✓ Коэффициент динамизма (Din)
- ✓ Коэффициент связности текста (Con)

Реализация прагматикона языковой личности

- ✓ Предложения с однородными рядами
- ✓ Предложения с обособленными приложениями
- ✓ Вводные слова и конструкции
- ✓ Целевые и выделительные обороты
- ✓ Синтаксические сращения
- ✓ Сравнительные придаточные
- ✓ Конструкции с сопоставительными союзами
- ✓ Вставные конструкции
- ✓ Сложные синтаксические конструкции
- ✓ Глагольные односоставные предложения
- ✓ Обращения

Описание тезауруса языковой личности

- ✓ Ключевые слова
- ✓ Наиболее частотные биграммы
- ✓ Наиболее частотные триграммы
- ✓ Дихотомия "свой/чужой"

Экспликация вербально-семантического уровня языковой личности

- ✓ Сложные слова полуслитного написания
- ✓ Модальные частицы
- ✓ Междометия
- ✓ Наличие/отсутствие модального постфикса «-то»
- ✓ Предпочтительные слова-интенсификаторы
- ✓ Количество слов несловарного написания

Набор предустановленных текстовых параметров ресурса: <http://khorom-attribution.ru/#/>



Описанная выше модель получила реализацию в виде прототипа программного продукта, размещенного в открытом доступе в сети Интернет, URL: <http://khorom-attribution.ru/#/>

Модуль пользователя:

Ввод данных: на вход подаются два текста А и В; пользователь имеет возможность ввести текст с клавиатуры или загрузить его с компьютера, а также выбрать жанр

1 Первый текст
Обязательный шаг

2 Второй текст
Обязательный шаг

3 Выбор атрибутов
Опциональный шаг

4 Результаты
Просмотр результатов

Жанр
художественная проза

Загрузите первый текст

Кодировка
Windows-1251

Первый текст
Обязательный шаг

художественная проза

сетевая литература

сетевая публицистика

сетевая развлекательная публицистика

корпоративная переписка

Введите первый текст



Пользователь может строить модель не только на основе предустановленных параметров, но и имеет возможность выбирать те, которые считает наиболее релевантными для определенной пары текстов, те, которые, по его мнению, дают наибольший прирост информации (функция множественного выбора)

Описание тезауруса языковой личности

- Ключевые слова
- Наиболее частотные биграммы
- Наиболее частотные триграммы
- Дихотомия "свой/чужой"

Экспликация вербально-семантического уровня языковой личности

- Сложные слова полуслитного написания
- Модальные частицы
- Междометия
- Наличие/отсутствие модального постфикса «-то»
- Предпочтительные слова-интенсификаторы
- Количество слов несловарного написания

Визуализация функции множественного выбора ресурса: <http://khorom-attribution.ru/#/>



Вывод данных: в качестве результата выводится значения коэффициента корреляции Пирсона, значение линейной регрессии, критерия Стьюдента для моделей двух сравниваемых текстов, а также значения метрик каждого параметра для двух текстов

Коэффициент корреляции Пирсона: 1

Линейная регрессия: p-value - 0, r-value - 1, stderr - 0.01

t-критерий Стьюдента: p-value - 0.99, statistic - 0.01

Корреляция по ключевым словам: -0.22

Корреляция по словам-интенсификаторам: -0.48

Корреляция по биграммам: -0.21

Корреляция по триграммам: -0.86

ID ↑	Атрибут	Текст 1	Текст 2
1	Индекс удобочитаемости Флеша-Кинкейда	12.7025	14.6661
2	Индекс туманности Ганнинга	15.8154	18.4731
3	Средняя длина слова (в буквах)	5.0144	5.4463
4	Средняя длина предложения (в словах)	9.9518	9.48
5	Количество предложений длиннее 8-ми слов	451754.386	442857.1429
6	Коэффициент предметности (Pr)	1.081	1.2082
7	Коэффициент качества (Qu)	0.2957	0.3731
8	Коэффициент активности (Ac)	0.2234	0.2019

Визуализация вывода результата ресурса:

<http://khorom-attribution.ru/#/>

Вывод данных: для пользователя также запрограммирован модуль проверки: выбрав вкладку Вспомогательные параметры можно просмотреть все выделенные в тексте компоненты, для которых рассчитаны относительные частоты и иные метрики

ID ↑	Атрибут	Текст 1	Текст 2	Просмотр
12	Количество союзов	2	1	
13	Количество орфографических ошибок	0	1	
14	Предложения с однородными рядами	0	0	
15	Вводные слова и конструкции	2	0	
16	Целевые, выделительные и сравнительные обороты	0	0	
17	Синтаксические сращения	0	0	
18	Сравнительные придаточные	0	0	
19	Сопоставительные придаточные	0	0	
20	Вставные конструкции	0	0	

ВСПОМОГАТЕЛЬНЫЕ ПАРАМЕТРЫ				
↑	Атрибут	Текст 1	Текст 2	Просмотр
	Количество союзов	2	1	
	Количество орфографических ошибок	0	1	
	Предложения с однородными рядами	0	0	
	Вводные слова и конструкции	2	0	
	Целевые, выделительные и сравнительные обороты	0	0	
	Синтаксические сращения	0	0	
	Сравнительные придаточные	0	0	
	Сопоставительные придаточные	0	0	
	Вставные конструкции	0	0	

Вводные слова и конструкции

ТЕКСТ 1 ТЕКСТ 2

Может быть, еще и заблудимся, – подумала она.

– Хлеба у нас взято довольно, есть бутылка молока, и картошка, может быть, тоже пригодится

Визуализация функции просмотра подробного
результата исследования на ресурсе: [http://khorom-
attribution.ru/#/](http://khorom-attribution.ru/#/)



Материал исследования

Ввод данных: на вход подаются два текста А и В; пользователь имеет возможность ввести текст с клавиатуры или загрузить его с компьютера, а также выбрать жанр

- 1) Подкорпус текстов сетевой газеты «The Village» (сетевая публицистика): включает в себя тексты 3 авторов-женщин, 3 авторов-мужчин; всего 600 текстов
- 2) Подкорпус текстов развлекательного портала «ЯПлакалъ» (развлекательная публицистика, комментарии, форум): включает в себя тексты 3 авторов-женщин, 3 авторов-мужчин; всего 600 текстов
- 3) Подкорпус текстов ресурса сетевой литературы «Книга фанфиков» (<https://ficbook.net/>): включает в себя тексты 3 авторов-женщин, 4 авторов-мужчин; всего 190 текстов
- 4) Подкорпус текстов художественной литературы (нежанровая проза), включающий тексты С.Д.Довлатова и В.П.Астафьева: 10 текстов (С.Д.Довлатова «Наши», «Чемодан», «Иностранка», «Заповедник», «Зона: Записки надзирателя», «Встретились, поговорили», В.П.Астафьева «Обертон», «Последний поклон», «Звездопад», «Так хочется жить»);
- 5) Подкорпус текстов корпоративной русскоязычной переписки: 2 автора-женщины, 2 автора-мужчины, всего 218 текстов.



Выводы

В настоящий момент происходит процесс финального тестирования и отладки ресурса. Данные текстовые коллекции позволяют разработчикам всесторонне проверить его работоспособность и валидность получаемых результатов.

Но уже на этом этапе можно говорить о том, что наибольший прирост информации при определении автора текста любого жанра и объема дают такие параметры, как:

- слова-интенсификаторы, количество слов несловарного написания на вербально-семантическом уровне языковой личности;
- ключевые слова, показатели дихотомии «свой/чужой», наиболее частотные биграммы на уровне тезауруса личности;
- сложные и осложненные синтаксические конструкции (вид конструкции зависит от жанра текстов: для публицистики, например, это предложения с однородными рядами, предложения с обособленными приложениями, конструкции с сопоставительными союзами, вставные конструкции; для художественных текстов это глагольные односоставные предложения, придаточные сравнительные, сложные синтаксические конструкции, вставные конструкции) на уровне прагматикона личности.

Спасибо за внимание!



НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
УНИВЕРСИТЕТ

Хоменко Анна Юрьевна:

akhomenko@hse.ru

<https://www.hse.ru/org/persons/65858472>