

Применение частотного анализа в соционике

Новая методика определения авторства текста

Постановка задачи

Пусть дан текст на русском языке. Попробуем решить следующие задачи:

1. Определение автора из множества известных, книги которых у нас уже проанализированы.
2. Определение основных факторов оказывающих наибольшее влияние на распределение частот.
3. Определение соционического типа автора текста с помощью частотного анализа.

Новая методика определения авторства по тексту на естественном языке

Первая попытка создания методики для определения автора текста была сделана еще в самом начале 20-го века.

Уже в наше время была предложена интересная методика определения авторства текста с использованием статистических методов.

Известный пример с определением авторства романа "Тихий Дон", об ответе на которой спорят многие исследователи.

- Средняя длина слова в буквах, вычисляемая на основании выборок размером 500 текстов.
- Общее распределение длины слова.
- Средняя длина предложения в словах, вычисляемая на основании выборок размером в 30.
- Общее распределение длины предложения.
- Лексический спектр текста на уровне словаря.
- Лексический спектр текста на уровне текста.
- Индекс разнообразия лексики.

С помощью нее он провел компьютерный анализ текстов Шолохова, подтвердивший его авторство.

Известно, что клуб любителей творчества Пушкина собирал информацию о частотном распределении слов.

Методика, которая описывается в этой статье, была случайно получена мной в качестве побочного продукта.

Слова русского языка имеют огромную разницу в распределении частот. Например, слово "время" встречается гораздо чаще, чем "минута".

В базу данных Oracle были закачаны результаты частотного анализа 104 книг 38 человек (количество слов).

Алгоритм

- Составление частотного словаря для каждой книги.
- На основе нескольких книг создается частотный словарь писателя.
- С помощью частотного словаря Шарова происходит нормализация. То есть полученные значения нормализуются.
- Вводится понятие расстояния между словарями, как сумма квадратов разностей частот между словами.
- При этом если слово есть в одном словаре, но совсем отсутствует в другом, то оно не учитывается.
- Учитываются первые 5000-10000 наиболее употребляемых слов русского языка.
- В качестве результата берется словарь с минимальным расстоянием.

Если взять больше 10000 слов, то редкие слова оказывают слишком большое влияние на результаты.

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

По данному методу для всех 104 книг автор был определен верно в 102 случаях с двумя ошибками

Были взяты 38 словарей писателей. 104 словаря для книг, в том числе пять из них Льва Толстого



Автор

Произведение

Расстояние

1

Лев Толстой

Юность

0

2

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Лев Толстой

Частотный словарь автора

168

3

Лев Толстой

Детство

289

4

Лев Толстой

Война и мир. Том 2

307

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

5

Джек Лондон

Частотный словарь автора

373

6

Герман Гессе

Эссе

385

7

Николай Гоголь

Частотный словарь автора

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

393

8

Герман Гессе

Частотный словарь автора

396

9

Федор Достоевский

Частотный словарь автора

403

10

Федор Достоевский

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Записки из мертвого дома

404

11

Иван Тургенев

Новь

406

12

Лев Толстой

Хаджи-Мурат

415

13

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Иван Тургенев

Кзаки

421

14

Лев Толстой

Частотный словарь автора

422

...

...

...

...

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

142

Жан-Поль Сартр

Частотный словарь автора

8668

Отсюда видно, что все пять книг Толстого плюс словарь писателя попали на первые 14 позиций, то есть книги Толстого находятся достаточно близко друг к другу, поэтому чем больше будет проанализировано данных для составления частотных словарей писателей, тем более надежным будет результат.

Жанр произведений

Но вернемся к Пушкину и одной из ошибок определения автора по тому 7 "История Пугачева. Исторические статьи и материалы":



Автор

Произведение

Расстояние

1

Александр Пушкин

Том 7 История Пугачева. Исторические статьи и материалы

0

2

Станислав Лем

Звездные дневники Йохана Тихого

341

3

Джек Лондон

Частотный словарь автора

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

363

4

Станислав Лем

Частотный словарь автора

364

5

Антон Чехов

Частотный словарь автора

375

6

Герман Гессе

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Эссе

397

...

...

...

...

39

Александр Пушкин

Частотный словарь автора

545

...

...

...

...

49

Александр Пушкин

Том 2 Стихотворения 1823-1836

575

...

...

...

...

71

Александр Пушкин

Том 4 Евгений Онегин Драматические произведения

650

...

...

...

...

73

Александр Пушкин

Том 1 Стихотворения 1814-1822

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

657

...

...

...

...

129

Александр Пушкин

Том 9 Письма

2436

...

...

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

...

...

и к правильному определению автора по тому 2 "Стихотворения 1823-1936":

№

Автор

Произведение

Расстояние

1

Александр Пушкин

Том 2 Стихотворения 1823-1836

0

2

Александр Пушкин

53

3

Александр Пушкин

Том 1 Стихотворения 1814-1822

143

4

Александр Пушкин

Том 3 Поэмы, сказки

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

144

5

Александр Пушкин

Том 4 Евгений Онегин Драматические произведения

162

6

Антон Чехов

Рассказы

420

...

...

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

...

...

35

Александр Пушкин

Том 7 История Пугачева. Исторические статьи и материалы

575

...

...

...

...

130

Александр Пушкин

Том 9 Письма

2456

...

...

...

...

Вывод, который напрашивается из этих двух таблиц: есть три достаточно далеко расположенные друг от друга группы произведений Пушкина: поэзия (Томы 1-4), письма (Том 9) и проза (Том 7 "История Пугачева. Исторические статьи и материалы"). Таким образом наглядно показано, что кроме собственно авторства частота слов в тексте очень сильно зависит от жанра произведений.

Еще одно подтверждение этого было получено, когда были проанализированы два ЖЖ-дневника (авторы имеют психологические типы СЭЭ и ЛСЭ) и сообщения на форуме (автор СЛИ). Казалась бы большое расхождение должны были бы дать разница в стиле, возрасте, образе жизни, психотипе и словарном запасе. Один из словарей был составлен по дневнику журналистки Таты Олейник (Почти_новая_горжетка), у которой словарный запас оказался самым большим по первым 80 книгам. Тем не менее по

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

данной методике расстояния между этими тремя словарями получились относительно небольшими, для одного из словарей два других оказались ближайшими из 37 словарей. Таким образом язык on-line дневников и форумов, близкий к разговорному сильно отличается от литературного и научного, причем это отличие можно выявить с помощью данной методики или ее модификации. А значит ее можно применять для больших социологических и психолингвистических исследований русского языка на больших корпусах текстов.

Предметная область

Полную версию таблицы расстояний между 28 словарями писателей, психологов и социоников в базе данных можно посмотреть [здесь](#). В качестве психотипа стоит моя версия

Далее проанализируем полученную таблицу. Отсортируем список по возрастанию расстояния от словаря Агаты Кристи:



Автор

ТИМ

Расстояние

Профессия

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

1

Агата Кристи

СЛИ

0

писатель

2

Иван Тургенев

ЭСИ

242

писатель

3

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Станислав Лем

ИЛИ

256

писатель

4

Антон Чехов

ЛИИ

285

писатель

5

Федор Достоевский

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ЭИИ

286

писатель

6

Джек Лондон

ЛИЭ

322

писатель

7

Теодор Драйзер

ЭСИ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

350

писатель

8

Виктор Гюго

ЭСЭ

351

писатель

9

Николай Гоголь

ЭИЭ

355

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

10

Лев Толстой

СЭЭ

356

писатель

11

Жюль Верн

ЭСЭ

382

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

12

Пауло Коэльо

ЭИИ

386

писатель

13

Гарсия Маркес

ЭСЭ

401

писатель

14

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Ги де Мопассан

СЛИ

420

писатель

15

Герман Гессе

ИЛИ

428

писатель

16

Зигмунд Фрейд

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ИЛЭ

552

ПСИХОЛОГ

17

Карл Юнг

ИЛИ

574

ПСИХОЛОГ

18

Эрик Берн

ИЛЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

713

ПСИХОЛОГ

19

Александр Пушкин

ИЭЭ

725

ПОЭТ

20

Иван Крылов

ИЛИ

742

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

баснописец

21

Билл Гейтс

ЛИЭ

790

бизнесмен

22

Абрахам Маслоу

ИЭЭ

850

психолог

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

23

Эрих Фромм

ЭИИ

932

ПСИХОЛОГ

24

Екатерина Филатова

ЭИИ

952

СОЦИОНИК

25

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Жан-Поль Сартр

СЛИ

952

философ

26

Виктор Гуленко

ЛИИ

1 040

СОЦИОНИК

27

Аушра Аугустинавичюте

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ИЛЭ

2 604

СОЦИОНИК

28

Александр Лоуэн

СЭИ

3 381

ПСИХОЛОГ

Все писатели сверху! Отсюда следует, что профессия, а значит и предметная область существенно влияют на частотный анализ.

Аналогично отсортируем список по возрастанию расстояния от словаря Абрахама Маслоу:



Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Автор

ТИМ

Расстояние

Профессия

1

Абрахам Маслоу

ИЭЭ

0

психолог

2

Карл Юнг

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ИЛИ

294

психолог

3

Эрих Фромм

ЭИИ

295

психолог

4

Зигмунд Фрейд

ИЛЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

369

психолог

5

Эрик Берн

ИЛЭ

479

психолог

6

Пауло Коэльо

ЭИИ

653

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

7

Станислав Лем

ИЛИ

654

писатель

8

Антон Чехов

ЛИИ

691

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

9

Билл Гейтс

ЛИЭ

695

бизнесмен

10

Герман Гессе

ИЛИ

707

писатель

11

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Екатерина Филатова

ЭИИ

708

СОЦИОНИК

12

Лев Толстой

СЭЭ

719

писатель

13

Виктор Гюго

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ЭСЭ

727

писатель

14

Джек Лондон

ЛИЭ

728

писатель

15

Жюль Верн

ЭСЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

751

писатель

16

Иван Тургенев

ЭСИ

781

писатель

17

Теодор Драйзер

ЭСИ

793

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

18

Федор Достоевский

ЭИИ

830

писатель

19

Агата Кристи

СЛИ

850

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

20

Николай Гоголь

ЭИЭ

851

писатель

21

Ги де Мопассан

СЛИ

866

писатель

22

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Гарсия Маркес

ЭСЭ

898

писатель

23

Виктор Гуленко

ЛИИ

914

СОЦИОНИК

24

Александр Пушкин

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ИЭЭ

1 075

поэт

25

Иван Крылов

ИЛИ

1 238

баснописец

26

Жан-Поль Сартр

СЛИ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

1 581

философ

27

Аушра Аугустинавичюте

ИЛЭ

1 707

СОЦИОНИК

28

Александр Лоуэн

СЭИ

2 968

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

психолог

Заметим, что наиболее близкими оказались словари практически всех психологов за исключением Александра Лоуэна.

Теперь проверим остается ли действовать это правило для социоников:



Автор

ТИМ

Расстояние

Профессия

1

Аушра Аугустинавичюте

ИЛЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

0

СОЦИОНИК

2

Екатерина Филатова

ЭИИ

1 169

СОЦИОНИК

3

Виктор Гуленко

ЛИИ

1 294

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

СОЦИОНИК

4

Зигмунд Фрейд

ИЛЭ

1 578

ПСИХОЛОГ

5

Эрих Фромм

ЭИИ

1 670

ПСИХОЛОГ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

6

Карл Юнг

ИЛИ

1 703

психолог

7

Абрахам Маслоу

ИЭЭ

1 707

психолог

8

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Эрик Берн

ИЛЭ

1 709

психолог

9

Пауло Коэльо

ЭИИ

2 143

писатель

10

Лев Толстой

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

СЭЭ

2 154

писатель

11

Антон Чехов

ЛИИ

2 272

писатель

12

Билл Гейтс

ЛИЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

2 284

бизнесмен

13

Герман Гессе

ИЛИ

2 307

писатель

14

Джек Лондон

ЛИЭ

2 346

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

15

Теодор Драйзер

ЭСИ

2 369

писатель

16

Иван Тургенев

ЭСИ

2 378

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

17

Станислав Лем

ИЛИ

2 401

писатель

18

Виктор Гюго

ЭСЭ

2 433

писатель

19

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Ги де Мопассан

СЛИ

2 470

писатель

20

Николай Гоголь

ЭИЭ

2 505

писатель

21

Жюль Верн

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ЭСЭ

2 510

писатель

22

Федор Достоевский

ЭИИ

2 529

писатель

23

Гарсия Маркес

ИЛИ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

2 544

писатель

24

Александр Пушкин

ИЭЭ

2 591

поэт

25

Агата Кристи

СЛИ

2 604

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

26

Иван Крылов

ИЛИ

2 968

баснописец

27

Жан-Поль Сартр

СЛИ

3 194

философ

28

Александр Лоуэн

СЭИ

3 861

психолог

Соционики сверху, далее подряд все психологи, опять же за исключением Лоуэна. Таким образом наша гипотеза о существенном влиянии предметной области на распределение частот слов в тексте еще раз подтвердилась.

Хотя это правило выполняется не всегда, например, для Гуленко, словарь Филатовой опять же оказывается сверху, но словарь Аушры находится в конце списка.

Так почему же словарь Лоуэна расположен настолько далеко от остальных психологов?

Объем анализируемого текста

Для ответа на этот вопрос построим таблицу для самого Лоуэна:

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22



Автор

ТИМ

Расстояние

Профессия

Объем текста

1

Александр Лоуэн

СЭИ

0

психолог

28 816

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

2

Зигмунд Фрейд

ИЛЭ

2 698

психолог

229 669

3

Карл Юнг

ИЛИ

2 778

психолог

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

206 119

4

Эрих Фромм

ЭИИ

2 928

психолог

123 063

5

Абрахам Маслоу

ИЭЭ

2 968

психолог

72 763

6

Гарсия Маркес

ЭСЭ

2 993

писатель

31 583

7

Пауло Коэльо

ЭИИ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

2 998

писатель

206 341

8

Джек Лондон

ЛИЭ

3 009

писатель

518 348

9

Лев Толстой

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

СЭЭ

3 017

писатель

256 137

10

Станислав Лем

ИЛИ

3 023

писатель

180 395

11

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Герман Гессе

ИЛИ

3 069

писатель

115 476

12

Николай Гоголь

ЭИЭ

3 087

писатель

166 778

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

13

Екатерина Филатова

ЭИИ

3 109

СОЦИОНИК

157 332

14

Ги де Мопассан

СЛИ

3 111

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

60 620

15

Эрик Берн

ИЛЭ

3 155

психолог

110 248

16

Виктор Гюго

ЭСЭ

3 162

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

774 221

17

Иван Тургенев

ЭСИ

3 171

писатель

257 121

18

Антон Чехов

ЛИИ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

3 181

писатель

209 448

19

Виктор Гуленко

ЛИИ

3 248

СОЦИОНИК

33 628

20

Теодор Драйзер

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ЭСИ

3 266

писатель

245 036

21

Жюль Верн

ЭСЭ

3 316

писатель

143 855

22

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Федор Достоевский

ЭИИ

3 316

писатель

382 849

23

Агата Кристи

СЛИ

3 381

писатель

140 406

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

24

Билл Гейтс

ЛИЭ

3 390

бизнесмен

87 808

25

Александр Пушкин

ИЭЭ

3 536

поэт

340 188

26

Иван Крылов

ИЛИ

3 738

баснописец

7 545

27

Аушра Аугустинавичюте

ИЛЭ

3 861

СОЦИОНИК

19 135

28

Жан-Поль Сартр

СЛИ

4 037

философ

14 477

Получается, что для самого Лоуэна словари психологов оказываются ближе, чем все остальные. Так в чем же дело? Мне кажется в данном случае есть две основные причины:

- Для анализа была взята книга "Вы и ваше тело" по телесно-ориентированной терапии, которая отличается от остальных психологических направлений своеобразием лексики достаточно сильно
- В последнем столбце указано количество анализируемых слов. Для Лоуэна, Аушры, Сартра, Крылова оно относительно мало. Хотя эта проблема частично решается пятым пунктом алгоритма, малое количество анализируемых слов делает словарь неустойчивым.

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Еще одним фактор, который может воздействовать на частоту вхождения слов, время написания книги, подробно не анализировался.

А теперь переходим к самому интересному для социоников.

Попытка определения психотипа

Отсортируем список по возрастанию расстояния от словаря Германа Гессе:



Автор

ТИМ

Расстояние

Профессия

1

Герман Гессе

<i>или</i>

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

0

писатель

2

Лев Толстой

СЭЭ

213

писатель

3

Джек Лондон

ЛИЭ

234

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

4

Иван Тургенев

ЭСИ

240

писатель

5

Пауло Коэльо

ЭИИ

256

писатель

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

6

Ги де Мопассан

СЛИ

261

писатель

7

Станислав Лем

ИЛИ

265

писатель

8

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Виктор Гюго

ЭСЭ

283

писатель

9

Антон Чехов

ЛИИ

302

писатель

10

Теодор Драйзер

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ЭСИ

305

писатель

11

Федор Достоевский

ЭИИ

312

писатель

12

Гарсия Маркес

ЭСЭ

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

336

писатель

13

Николай Гоголь

ЭИЭ

348

писатель

14

Жюль Верн

ЭСЭ

407

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

писатель

15

Агата Кристи

СЛИ

428

писатель

16

Александр Пушкин

ИЭЭ

450

поэт

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

17

Карл Юнг

или

485

ПСИХОЛОГ

18

Зигмунд Фрейд

ИЛЭ

495

ПСИХОЛОГ

19

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Эрик Берн

ИЛЭ

654

психолог

20

Эрих Фромм

ЭИИ

705

психолог

21

Абрахам Маслоу

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

ИЭЭ

707

психолог

22

Билл Гейтс

ЛИЭ

712

бизнесмен

23

Иван Крылов

или

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

723

баснописец

24

Екатерина Филатова

ЭИИ

827

СОЦИОНИК

25

Жан-Поль Сартр

СЛИ

961

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

философ

26

Виктор Гуленко

ЛИИ

1 021

СОЦИОНИК

27

Аушра Аугустинавичюте

ИЛЭ

2 307

СОЦИОНИК

28

Александр Лоуэн

СЭИ

3 069

психолог

Опять все писатели сверху, то есть влияние предметной области определяется достаточно точно.

Но если посмотреть на психотип ИЛИ, то он получается разбросанным по всей таблице. Аналогичные результаты видны и в остальных таблицах, приводимых выше. Я собрал версии о психотипах известных людей большинства известных социоников и построил эталонный список на основе их анализа. В нем, как представители типа интуитивно-логических интровертов (ИЛИ), оказались Герман Гессе, Станислав Лем и Гарсия Маркес (мое мнение - ЭСЭ), по поводу психотипа Карла Густава Юнга мнения социоников разделились между ИЛИ и ЛИИ. В любом случае при замене версий типов Маркеса и Юнга на более распространенные общая картина не меняется, то есть данная методика, использующая частотный анализ первых 5000-10000 наиболее употребляемых слов не может дать определение психотипа (точнее совпадения с наиболее вероятными версиями).

Итак, в целом частотные словари оказались достаточно устойчивыми на больших массивах информации. То есть **каждый их нас обладает своим неповторимым частотным словарем и аналогично почерку его можно идентифицировать с достаточно большой вероятностью**.

Это дает надежду возможности определения психотипа на основе его анализа.

О семантическом подходе в соционике писали Вайсбанд, Филимонов, Ритчик, Шепетько, Аушра.

Прокофьева, Ермак, питерская группа социоников, а также авторы этого сайта (я и Елена Заманская) составили свои семантические словари по каждой из функций.

Первые же идеи, которая приходят в голову для модификации данной методики: отфильтровать слова русского языка и рассматривать только те, которые относят к наполнению соционических функций, а также попробовать использовать при типировании основные дихотомии Юнга и признаки Рейнина. Данное исследование было проведено. О его результатах читайте в следующей статье.

Заключение

Итак в данной статье:

1. Показано, что частотный словарь человека достаточно устойчив на больших объемах текста и неустойчив на малых.
2. Была предложена новая методика определения автора текста на естественном языке. Основными плюсами данной методики являются ее надежность, простота и возможность автоматического использования. К минусам можно отнести то, что анализируемый текст должен быть достаточно большим для надежного определения авторства. Возможно в дальнейшем удастся синтезировать ее с методикой Хетсо.
3. Показано, что на частоту употребления слов существенно влияет не только автор, но также предметная область, жанр и размер анализируемого текста.
4. Переводчик оказывает гораздо меньшее влияние на распределение частот.
5. С помощью частотного анализа по наиболее употребительным словам не удастся определять соционический тип без дополнительной фильтрации по семантическим словарям.

Автор: admin

02.07.2010 04:08 - Обновлено 18.10.2011 00:22

Полученные результаты показывают, что психотип влияет на частоту употребления слов в русском языке в целом меньше, чем предметная область, жанр и размер анализируемого текста.

Сам анализируемый текст должен быть достаточно большим, иначе выводы будут ненадежными!

Данная статья не претендует на полноценное исследование, так как, например, для оценки надежности новой методики определения авторства нужно обработать гораздо большее число книг и источников информации. Возможно я это сделаю в будущем.

Автор - [Хрулёв Олег](#)

Список литературы

1

Н.А. Морозов. Исследование объективного исследования древних документов

2

А.А. Марков. Об одном применении статистического метода

3

Г. Хетсо. Методика, основанная на методах математической статистики

4

Л.И. Бородкин. Математические методы и компьютер в задачах атрибуции текстов

5

О.В. Кукушкина, А.А. Попова, Д.В. Хорст

Определение авторства текста с использованием буквенной и грамматической

6

С.А. Шаров

Частотный словарь Шарова

7

Л.Н. Засорина

Частотный словарь Засориной

8

Р.М. Фрумкина

Психолингвистика