

ПРОБЛЕМА РАЗРЕШЕНИЯ «Ё»-ОМОГРАФОВ ПРИ СИНТЕЗЕ РЕЧИ ПО ТЕКСТУ

THE PROBLEM OF THE «Ё»-HOMOGRAPHS RESOLUTION IN TEXT-TO-SPEECH SYNTHESIS

Лобанов Б.М. (lobanov@newman.bas-net.by),

Объединенный институт проблем информатики НАН Беларуси, Минск, Беларусь



В статье рассматривается проблема адекватного разрешения неопределенностей в системах синтеза речи по тексту, связанных с частным случаем омонимии – графической «Ё»-омонимией. Рассмотрены статистические характеристики омографических пар, в том числе «Ё»-омографов. Исследованы статистические характеристики распределений внутри наиболее часто встречающихся пар «Ё»-омографов. Обсуждаются пути разрешения наиболее частотной омографической пары «ВСЁ» и «ВСЕ».

“Когда же расставите точки над «ё»? Ё моё!!!”

LobanoPhone - 2000

Введение

Проблема адекватного разрешения неопределенностей, связанных с омонимией, играет существенную роль в решении задач распознавания и синтеза речи. Наиболее важное значение эта проблема приобретает при решении задач преобразования «речь – текст» (распознавание речи), когда существенным является разрешение почти всех видов омонимии: синтаксической, грамматической, лексической, словообразовательной и фонетической (см. словарь лингвистических терминов [1]). Только один вид омонимии - графическая омонимия, не играет роли в решении задач распознавания речи. Зато этот единственный вид омонимов, называемых омографами, играет весьма существенную роль в задачах преобразования «текст – речь» (синтез речи). Игнорирование существования омографов нарушает смысловое восприятие синтезированной речи и дополнительно ухудшает её естественность. Нам не известно ни одной работы, направленной на анализ и решение проблемы адекватного разрешения неопределенностей при синтезе русской речи по тексту, связанных с существованием омографов. В данной работе мы попытаемся в какой-то степени заполнить этот пробел, опираясь на фактический материал, представленный в словаре омографов русского языка [2].

В русском языке существуют два источника графической омонимии: вариативность *словесного ударения*, местоположение которого в письменной речи не указывается (СУ-омографы), и письменная традиция не обязательного проставления необходимых точек на букве «Ё» («Ё»-омографы). Литера «Ё» была предложена княгиней Екатериной Дашковой в 1783 году, а в печати употреблена в 1795 году. Отдельной буквой она долгое время не считалась и в азбуку официально не входила. В русском языке буква «Ё» используется, чаще всего в тех позициях, где произношение [(j)o] образовалось из [(j)e], чем и объясняется производная от «Е» форма буквы, хотя с точки зрения фонетики логичней было бы поставить точки не над «Е», а над «О». Букве "Ё" - 225 лет. Хотя она родилась в Санкт Петербурге, однако 20 октября 2001 года в Ульяновске

открылся единственный в мире памятник букве "Ё" (см. фото).



Существует много различных мнений, как в пользу, так и против неперемного использования буквы «Ё» в печатном тексте (см. <http://www.yomaker.ru/>). С нашей позиции – позиции разработчиков систем синтеза речи по тексту – отсутствие в тексте «Ё» влечёт за собой дополнительные трудности, которые должны быть разрешены в той или иной степени. Простейшее решение – игнорирование проблемы – влечёт за собой дополнительные трудности в восприятии синтезированной речи и к раздражающему слух Е-канию. Данная работа посвящена исследованию статистических закономерностей проявления «Ё»-омонимии в различных текстах, а также обсуждению вопросов разрешения связанных с ней неопределённостей.

1. Статистические характеристики омографических пар

Статистические исследования проводились с использованием специально разработанной программы “HOMOGRAPH STATISTICS” и электронного словаря омографов, созданного на основе книжного словаря [2]. Целью исследования являлось определение статистической значимости «Ё»-омографов в общем списке «СУ»- и «Ё»-омографов [2], а также выявление особенностей статистических распределений только внутри подкласса «Ё»-омографов. Общее количество омографов, в соответствии с приведенными в [2] данными, составляет 3894 пар, из них «Ё»-омографов – только 232 пары.

Статистические характеристики определялись в отдельности для достаточно представительных и различных типов текстов:

- А.С. Пушкин – стихотворные произведения,
- Л.Н. Толстой – роман «Анна Каренина»,
- Б. Акунин, Д. Рубина, Л. Петрушевская – современная проза,
- Труды конференции «ДИАЛОГ-2006» - научная проза.

В таблице 1 приведены интегральные статистические характеристики этих текстов по всей совокупности омографов, содержащихся в словаре [2].

Таблица 1. Результаты теста по всем омографам

Тип текста	Общее количество слов в тексте	Общее количество пар омографов	Число различных пар омографов
<i>Словарь омографов [2]</i>	-	3894 (100%)	3894 (100%)
<i>А.С. Пушкин</i>	266.726 (100%)	9.421 (3,53%)	827 (21,2 %)
<i>Л.Н. Толстой</i>	279.448 (100%)	8.747 (3,13%)	680 (17,5%)
<i>Б. Акунин и др.</i>	379.277 (100%)	13.630 (3,59%)	1088 (27,9%)
<i>«ДИАЛОГ-2006»</i>	305.742 (100%)	7.195 (2,35%)	563 (14,5%)
Среднее количество	307.775 (100%)	3,15%	20,3%

Как видно из таблицы 1, выбранные тексты различных жанров имеют примерно одинаковый объём, в среднем – около 300 тыс. слов. Средний процент вхождения омографов составил 3,15%. Если считать, что среднее число слов на странице равно 650, то около 20-ти слов могут оказаться омографами. В случае их неадекватного раскрытия, как показывает опыт, это приводит к весьма негативному впечатлению при прослушивании синтезированной речи. Из таблицы видно также, что наибольшее количество омографов встречается в современной прозе, а наименьшее – в научном тексте. Очень интересный факт вытекает при рассмотрении 4-

го столбца таблицы: всего только порядка 20% от общего многообразия всех омографических пар встречается в проанализированных текстах! Это указывает на первостепенную важность этого подмножества в решении задач разрешения омографии.

В таблице 2 приведены статистические характеристики 4-х классов текстов по совокупности пар «Ё»-омографов, содержащихся в словаре [2].

Таблица 2. Результаты теста по «Ё»-омографам

Тип текста	Общее количество слов в тексте	Общее количество пар «Ё»-омографов	Число различных пар «Ё»-омографов
<i>Словарь омографов [2]</i>	-	232 (100%)	232 (100%)
<i>А.С. Пушкин</i>	266.726 (100%)	1.411 (0,53%)	71 (30,6%)
<i>Л.Н. Толстой</i>	279.448 (100%)	2.276 (0,81%)	56 (24,1%)
<i>Б. Акунин и др.</i>	379.277 (100%)	2.935 (0,77%)	82 (35,3%)
<i>«ДИАЛОГ-2006»</i>	305.742 (100%)	810 (0,26%)	49 (21,1%)
<i>Среднее количество</i>	307.77 (100%)	0,59%	27,8%

В сравнении с данными таблицы 1, средний процент вхождения «Ё»-омографов значительно ниже и составил 0,59%, что соответствует их общему количеству. Однако, если сравнить отношение количества всех пар омографов к количеству «Ё»-омографов: $3894/232=16,8$ и соответствующее отношение процентов их вхождения в тексты: $3,15/0,59=5,3$, то можно отметить более чем 5-ти кратную частотность «Ё»-омографов, а, следовательно, существенную важность разрешения этого вида омографии при синтезе речи. Как и в случае таблицы 1, только порядка 30% от общего многообразия всех «Ё»-омографических пар встречается в проанализированных текстах.

В таблице 3 приведены дифференциальные характеристики статистического анализа текстов по всей совокупности омографов (первые 15 наиболее частотных пар омографов), содержащихся в словаре [2]. Как видно из таблицы, во всех художественных текстах пара «Ё»-омографов слова «*все*» выдвинулась на 1-е место. В специфическом научном тексте «Диалог-06» омограф «*все*» уступил 1-е место, к нашему удовольствию, омографу «*слова*». Из таблицы видно также, что и некоторые другие «Ё»-омографы вошли в число наиболее частотных: «*перед, всем*». На рисунке 1 графически представлены распределения количества встречаемости в различных текстах 10-ти наиболее частотных пар омографов. Из рис. 1 видно, что пары омографов наиболее равномерно распределены (а, следовательно, наиболее информативны!) в стихотворных произведениях А.С. Пушкина и в научных трудах участников «ДИАЛОГа».

Таблица 3. Результаты теста по всем омографам

А.С. Пушкин		Л.Н. Толстой		Б. Акунин		Диалог-06	
<i>все</i>	458	<i>все</i>	1670	<i>все</i>	1963	<i>слова</i>	735
<i>уж</i>	436	<i>уже</i>	601	<i>уже</i>	811	<i>все</i>	433
<i>уже</i>	361	<i>надо</i>	376	<i>потом</i>	555	<i>уже</i>	247
<i>перед</i>	214	<i>потом</i>	229	<i>уж</i>	345	<i>связи</i>	184
<i>моя</i>	204	<i>глаза</i>	211	<i>глаза</i>	328	<i>части</i>	133
<i>всем</i>	132	<i>слова</i>	173	<i>надо</i>	319	<i>корпуса</i>	133
<i>глаза</i>	126	<i>уж</i>	164	<i>руки</i>	270	<i>стороны</i>	125
<i>сердца</i>	120	<i>тому</i>	144	<i>перед</i>	265	<i>правила</i>	124
<i>слова</i>	113	<i>голову</i>	143	<i>голову</i>	198	<i>правило</i>	118

<i>потом</i>	112	<i>руки</i>	143	<i>дома</i>	168	<i>оно</i>	114
<i>ночи</i>	108	<i>всем</i>	125	<i>всем</i>	141	<i>перед</i>	105
<i>тому</i>	98	<i>дома</i>	124	<i>самом</i>	137	<i>тона</i>	103
<i>пора</i>	95	<i>лица</i>	112	<i>слова</i>	127	<i>рода</i>	101
<i>души</i>	95	<i>дела</i>	100	<i>моя</i>	123	<i>второй</i>	93
<i>мою</i>	92	<i>должно</i>	91	<i>двери</i>	109	<i>свойства</i>	91

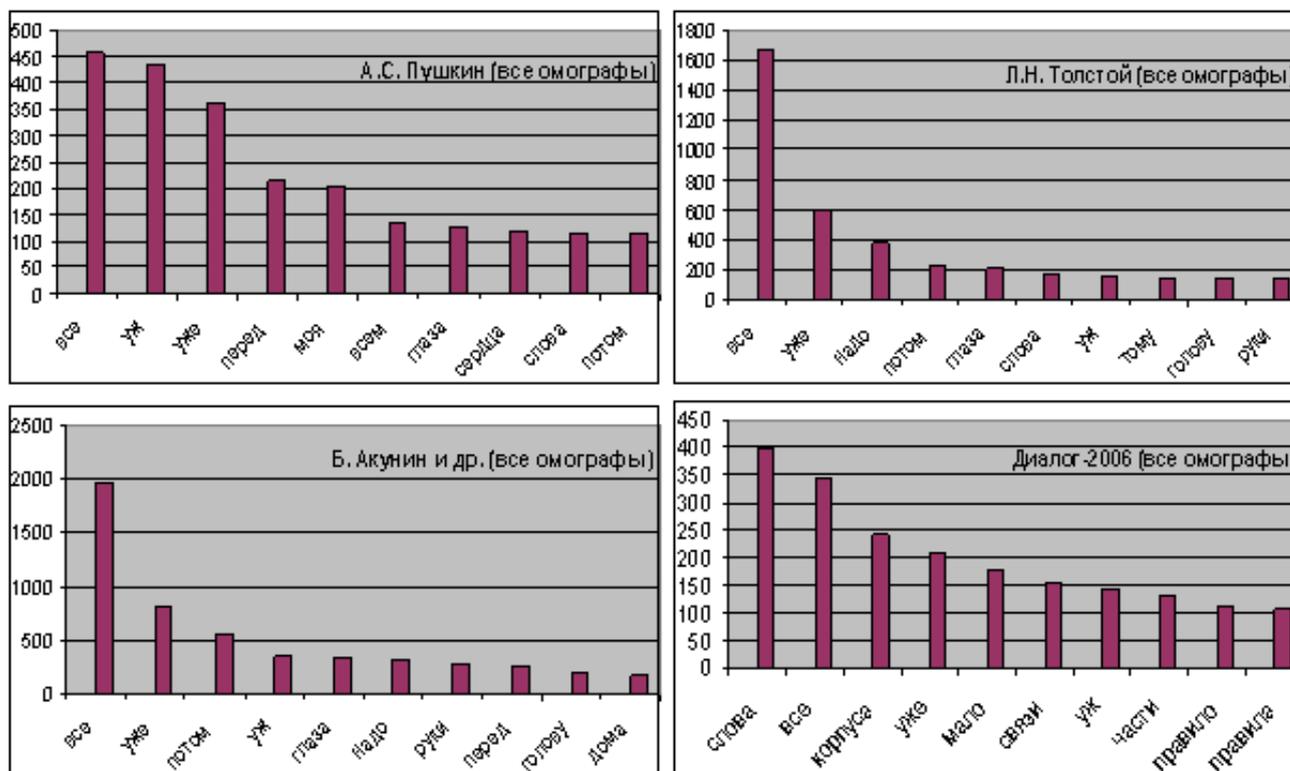


Рис.1. Распределения встречаемости пар омографов в различных текстах

В таблице 4 приведены дифференциальные статистические характеристики текстов – первые 15 наиболее частотных пар «Ё»-омографов, содержащихся в словаре [2]. Как и ожидалось 1-е места во всех текстах заняла пара омографов «все». Соответствующие таблице графические распределения представлены на рис. 2.

Таблица 4. Результаты теста по «Ё»-омографам

А.С. Пушкин		Л.Н. Толстой		Б. Акунин		Диалог-06	
<i>все</i>	458	<i>все</i>	1670	<i>все</i>	1963	<i>все</i>	433
<i>перед</i>	214	<i>всем</i>	125	<i>перед</i>	265	<i>перед</i>	105
<i>всем</i>	132	<i>жены</i>	78	<i>всем</i>	141	<i>всем</i>	41
<i>слезы</i>	92	<i>слезы</i>	53	<i>слезы</i>	56	<i>объем</i>	39
<i>небо</i>	50	<i>села</i>	45	<i>чем-то</i>	37	<i>надеж</i>	36
<i>села</i>	42	<i>перед</i>	35	<i>небо</i>	34	<i>пометы</i>	20
<i>жены</i>	37	<i>чем-то</i>	32	<i>села</i>	32	<i>небо</i>	14
<i>берег</i>	29	<i>сестры</i>	27	<i>щеки</i>	28	<i>помет</i>	12
<i>лета</i>	28	<i>умел</i>	22	<i>жены</i>	26	<i>берег</i>	10
<i>весны</i>	23	<i>чем-нибудь</i>	17	<i>сестры</i>	23	<i>чем-то</i>	9
<i>умел</i>	22	<i>небо</i>	14	<i>счета</i>	21	<i>ребра</i>	7
<i>небо</i>	21	<i>щеки</i>	11	<i>умел</i>	17	<i>запрет</i>	7
<i>смел</i>	18	<i>звезды</i>	9	<i>стекла</i>	17	<i>жены</i>	6

небом	15	весел	9	небе	14	полет	6
небе	14	весны	8	осел	14	черта	6
берет	13	черта	8	черта	13	села	4

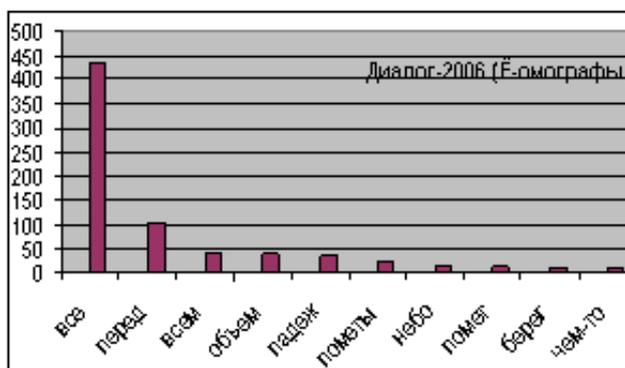
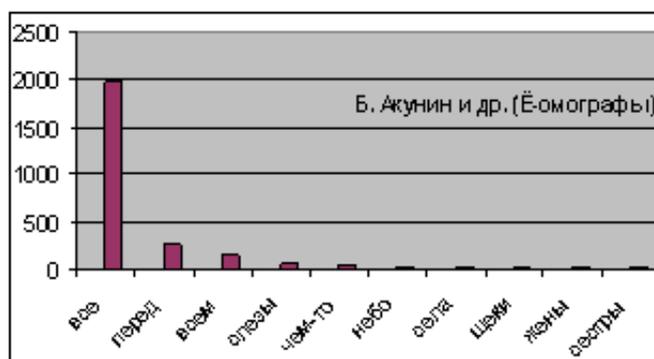
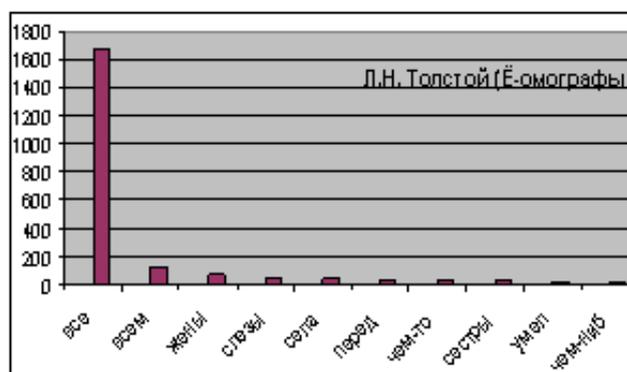
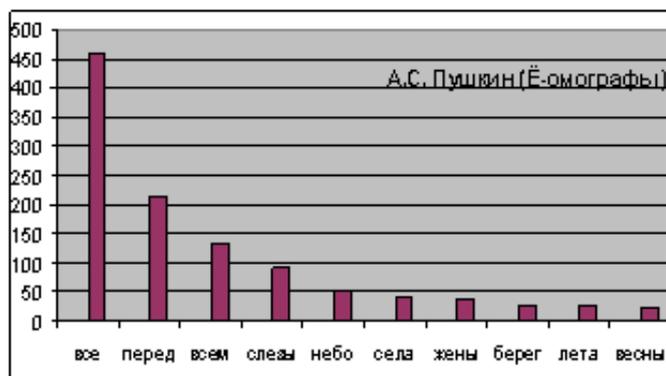


Рис.2. Распределения встречаемости пар «Ё»- омографов в различных текстах

2. Статистические характеристики распределений внутри пар «Ё»-омографов

Для определения статистических характеристик распределений внутри пар «Ё»-омографов использовались результаты описанного выше статистического анализа дифференциальных характеристик пар «Ё»-омографов и данные Интернет ресурса [3] “Поиск по акцентуированному корпусу”. Вначале из таблицы 4 были отобраны 10 наиболее частотных пар «Ё»-омографов по всем рассмотренным выше **4-м текстам** (помечены жирным шрифтом в табл. 4) и подсчитаны суммарные количества их встречаемости (см. столбец 2 таблицы 5 и рис.3). Затем для этих слов с помощью Интернет ресурса [3] в **Корпусе** текстов по драматургии, беллетристике, публицистике и научно-популярной литературе определены суммарные количества их встречаемости (см. столбец 3 таблицы 5 и рис. 3). В столбцах 4, 5 приведены результаты встречаемости в Корпусе [3] «Ё» и «Е» слов (см. также рис. 4), в столбцах 6, 7 – соотношение количества слов с «Ё» и «Е» в процентах внутри пар «Ё»-омографов (см. также рис. 5).

Таблица 5. Парная и внутрипарная встречаемость «Ё»-омографов

Пара «Ё»-омографов	Кол. пар в 4-х текстах	Кол. пар в Корпусе	Кол. Ё-слов в Корпусе	Кол. Е-слов в Корпусе	Соотношение внутри пар	
					% кол. «Ё»	% кол.«Е»
1	2	3	4	5	6	7
все	4524	5970	4143	1826	100	44
перед	620	640	0	640	0	100
всем	440	505	109	362	28	100
слезы	200	60	60	1	100	2

<i>села</i>	120	64	2	62	3	100
<i>небо</i>	100	126	0	126	0	100
<i>чем-то</i>	80	123	53	70	75,7	100
<i>жены</i>	64	49	14	35	40	100
<i>сестры</i>	52	34	24	10	100	42
<i>берег</i>	40	85	4	81	5	100

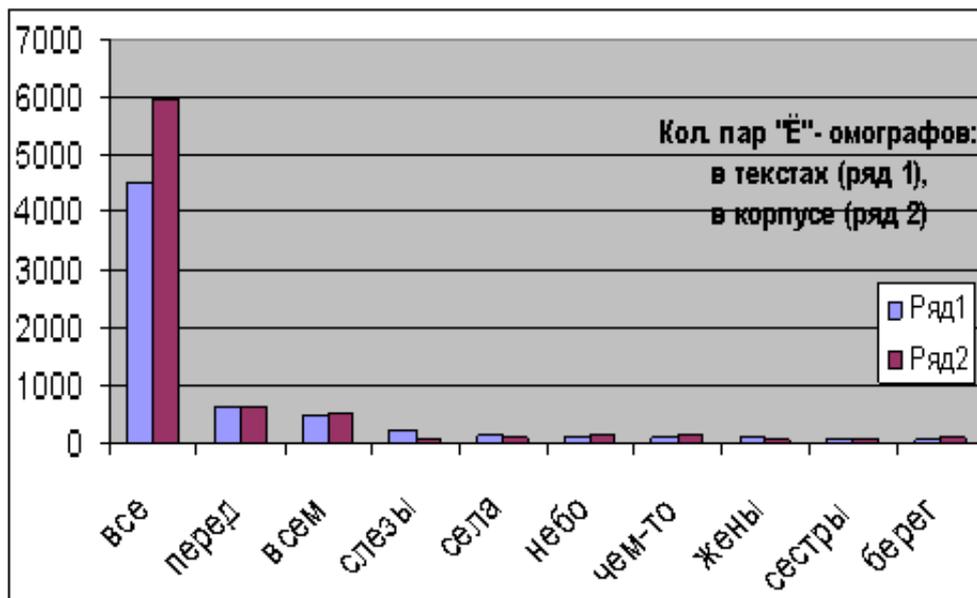


Рис.3. Распределения встречаемости 10-ти наиболее частотных пар «Ё»-омографов

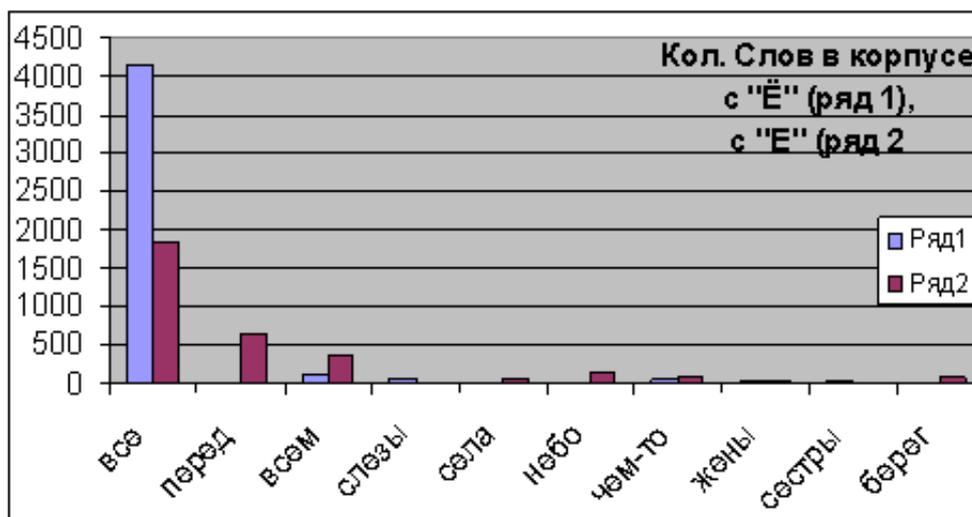


Рис. 4. Распределения кол. слов с «Ё» (ряд 1)- и «Е»(Ряд 2) внутри пар «Ё»-омографов

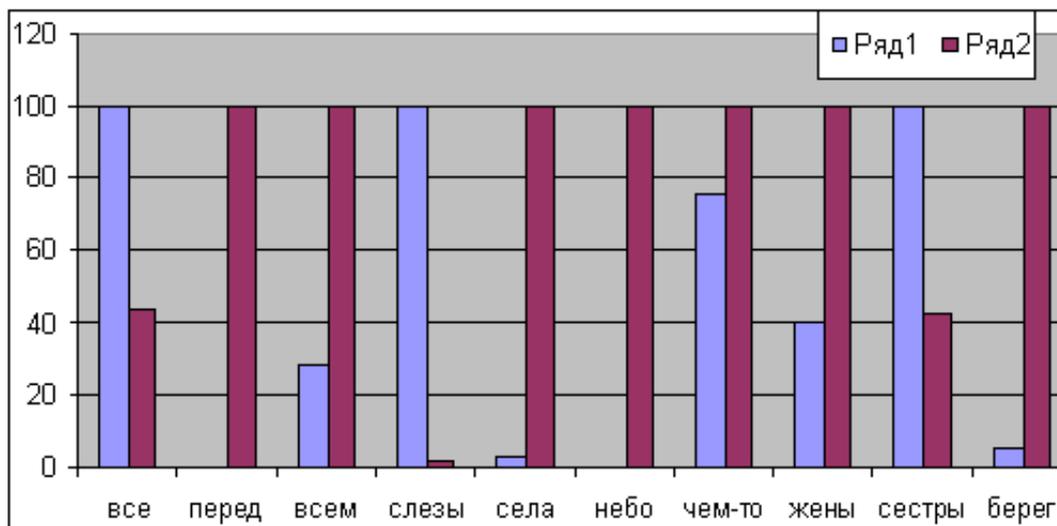


Рис. 5. Соотношения кол. слов в % с «Ё» (Ряд 1) и «Е» (Ряд 2) внутри пар «Ё»-омографов

3. Некоторые правила разрешения «Ё»-омографической неопределённости

Анализируя результаты, приведенные в таблице 5 и на рис. 3 – 4, можно сделать следующие выводы.

1. Как видно из табл. 5 (столбцы 2 и 3) использованная для статистического анализа выборка **Текстов** (А.С. Пушкин – стихотворные произведения, Л.Н. Толстой – роман «Анна Каренина», Борис Акунин, Дина Рубина, Людмила Петрушевская – современная проза, Труды конференции «ДИАЛОГ-2006» - научная проза) является достаточно представительной и сравнимой по объёму с **Корпусом** текстов по драматургии, беллетристике, публицистике и научно-популярной литературе, представленном в [3].
2. Полученные распределения встречаемости 10-ти наиболее частотных пар «Ё»-омографов в изученных **Текстах** и в **Корпусе** в высокой степени подобны (см. рис. 3), что говорит о достаточной степени достоверности полученных данных.
3. Из рис. 3 и 4 следует, что подавляющее количество «Ё»-омографов как **Текстах**, так и в **Корпусе** приходится на пару омографов «ВСЁ», что подчёркивает исключительную важность нахождения правил их разрешения при синтезе речи.
4. Из табл. 5 (столбцы 6, 7), а также из рис. 5 видно, что в 5-ти из 10-ти наиболее частотных пар «Ё»-омографов появление той или иной реализации омографа в паре более или менее равновероятно (пары: **ВСЁ_ВСЕ**, **ВСЁМ_ВСЕМ**, **ЧЁМ-ТО_ЧЕМ-ТО**, **ЖЁНЫ_ЖЕНЫ**, **СЁСТРЫ_СЕСТРЫ**). В оставшихся 5-ти парах с высокой степенью достоверностью можно выбирать варианты: **ПЕРЕД**, **СЛЁЗЫ**, **СЕЛА**, **НЕБО**, **БЕРЕГ**.
5. Для пар омографов: **ВСЁМ_ВСЕМ**, **ЧЁМ-ТО_ЧЕМ-ТО**, слова с «Ё» с высокой степенью достоверностью могут быть определены по наличию перед ними предлогов «о», «об» или «обо».
6. Для пар омографов: **ЖЁНЫ_ЖЕНЫ**, **СЁСТРЫ_СЕСТРЫ**, слова с «Ё» могут быть определены по их принадлежности к существительным множественного числа.
7. Наибольшую трудность представляет разрешение омографической неопределённости для слов **ВСЁ_ВСЕ**.

3.1.1. «ВСЁ» или «ВСЕ»?

Для разрешения омографической неопределённости пары **ВСЁ_ВСЕ** можно использовать некоторые эмпирически найденные контекстуальные правила, работающие с достаточно высокой степенью достоверностью. Для этой цели был проведен выборочный анализ встречаемости слов **ВСЁ** и **ВСЕ** в сочетании с другими словами в романе Б. Акунина «Азazelь», содержащего 55 тыс. слов. Было подсчитано количество сочетаний слова **ВСЁ** с различными словами или знаками препинания при условии, что слово **ВСЕ** ни разу не встретилось в тех же сочетаниях. Получены следующие наиболее частотные сочетания этого вида:

- ВСЁ+Любой Знак Прерывания – 24 раза
- ВСЁ+РАВНО – 21 раз
- ВСЁ+ ЭТО – 11 раз
- ВСЁ+ТАК(ТОТ, ТЕМ) ЖЕ – 9 раз
- ВСЁ ВРЕМЯ – 5 раз
- ВСЁ ЕЩЁ – 4 раза
- ВСЁ БЫЛО – 3 раза
- ВСЁ МОЖЕТ – 3 раза.

Определено также около 30 других сочетаний такого рода, встретившихся от 1-го до 2-х раз в проанализированном тексте.

Для более глубокого анализа возможностей разрешения омографической неопределённости пары **ВСЁ_ВСЕ** на том же тексте были проведены эксперименты с использованием синтаксического разбора предложений с использованием разработанной в Институте проблем передачи информации РАН системы ЭТАП-3, которая для каждого предложения строит синтаксическую структуру в виде дерева зависимостей [4]. На рис. 6 – 8 приведены примеры правильного синтаксического разбора предложения со словом **ВСЁ**. При правильном разборе омограф **ВСЁ** маркируется либо как местоимение-существительное (S) единственного числа среднего рода (рис.6), либо как местоимение-прилагательное (A) единственного числа среднего рода (рис. 7), либо как частица (PART), играющая роль ограничителя (рис. 8).

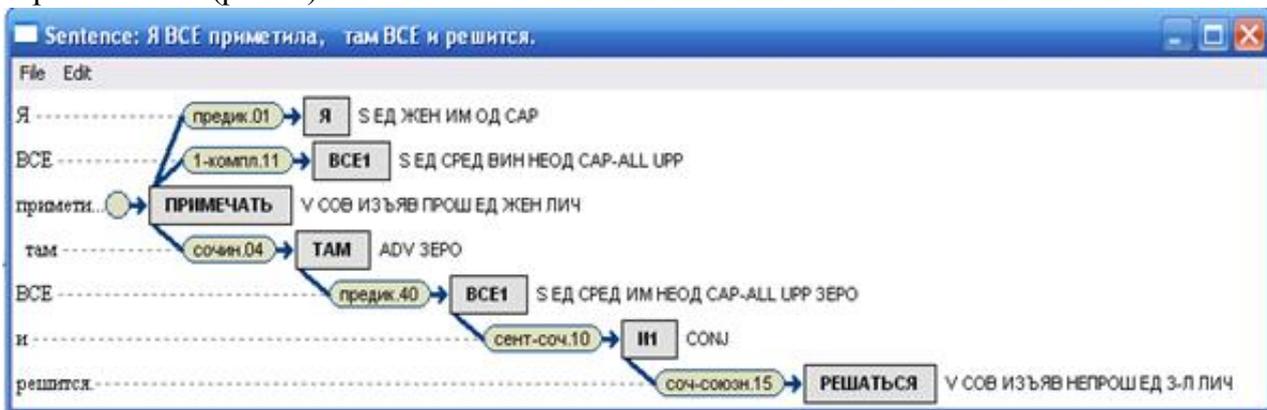


Рис. 6. Пример 1 правильного синтаксического разбора предложения со словом **ВСЁ**

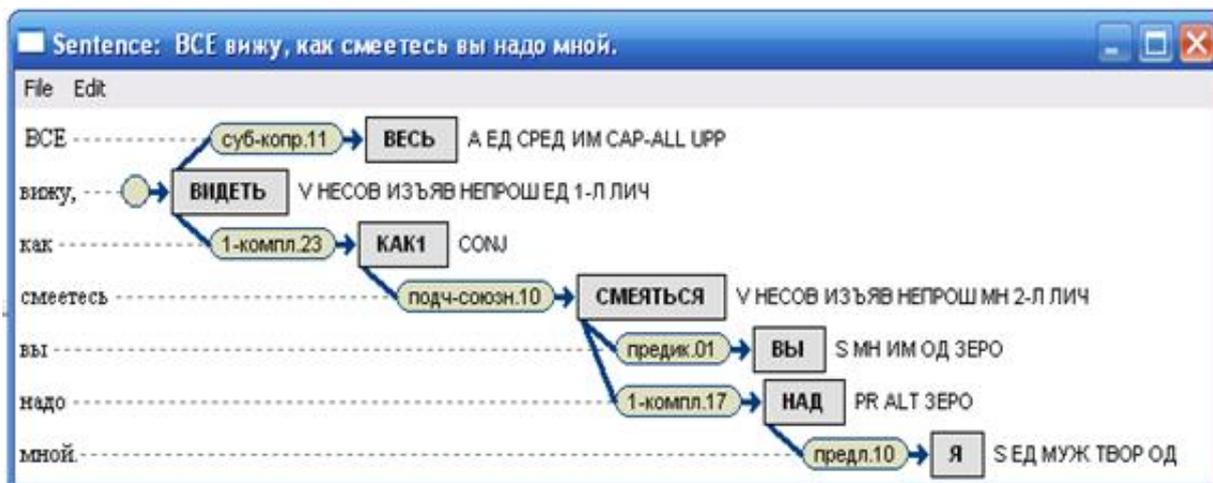


Рис. 7. Пример 2 правильного синтаксического разбора предложения со словом **ВСЁ**

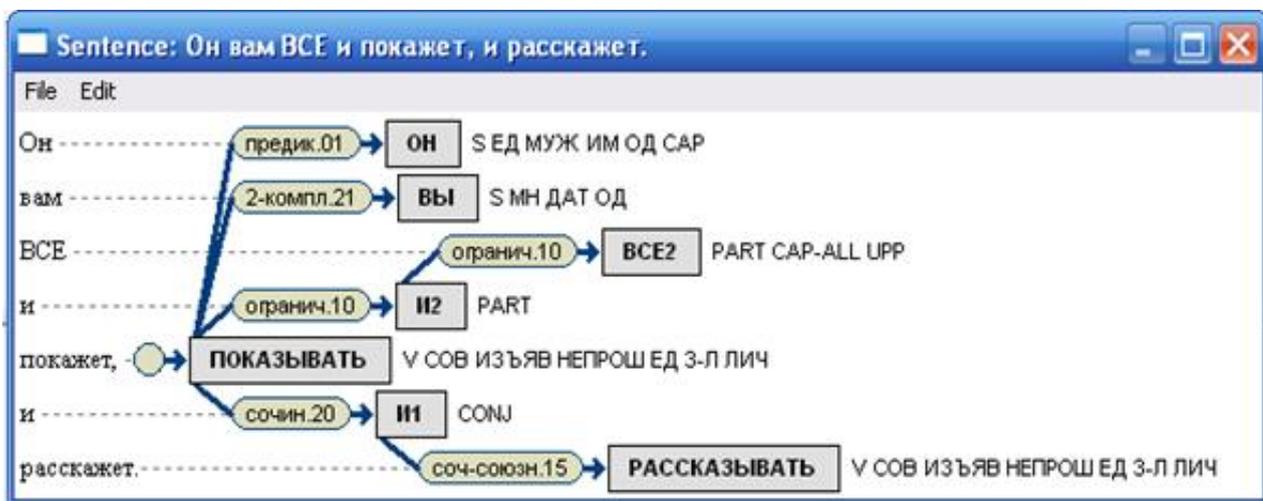


Рис. 8. Пример 3 правильного синтаксического разбора предложения со словом **ВСЁ**

На рис. 9 – 10 приведены примеры правильного синтаксического разбора предложения со словом **ВСЕ**. При правильном разборе омограф **ВСЕ** маркируется всегда как местоимение-существительное (А) множественного числа.



Рис. 9. Пример 1 правильного синтаксического разбора предложения со словом **ВСЕ**



Рис. 10. Пример 2 правильного синтаксического разбора предложения со словом **ВСЕ**

На рис. 11 и 12 приведены примеры неправильного синтаксического разбора предложения со словом **ВСЁ**. В этих примерах слово **ВСЁ** ошибочно распознано как **ВСЕ**, т.е. как местоимение-прилагательное (рис.11), либо как местоимение-существительное (рис.12) множественного числа.

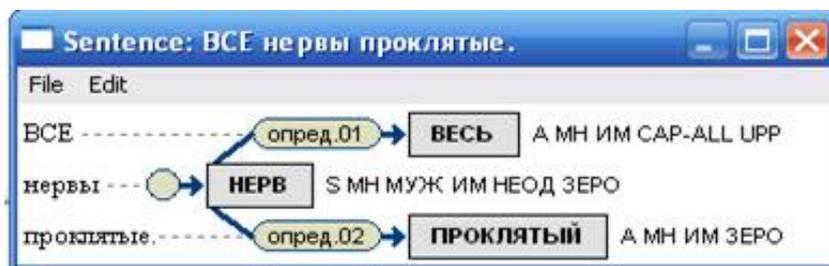


Рис. 11. Пример 1 неправильного синтаксического разбора предложения со словом **ВСЁ**

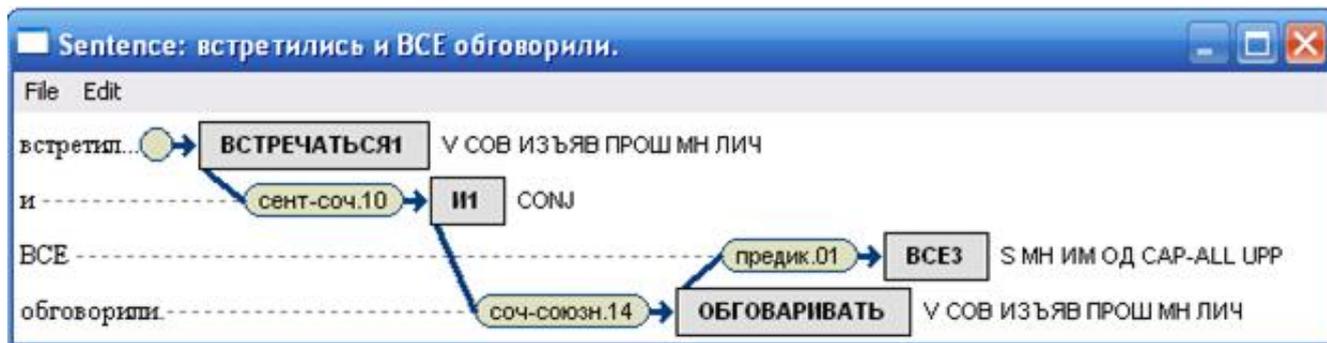


Рис. 12. Пример 2 неправильного синтаксического разбора предложения со словом **ВСЁ**

В заключение заметим, что при использовании системы ЭТАП-3 на всём протестированном тексте (роман Б. Акунина «Азazelь»), в котором присутствовало 123 вхождения омографа **ВСЕ**, обнаружено лишь 5 ошибочных отнесений слова **ВСЁ** к слову **ВСЕ**, т.е. только 4% ошибочного распознавания!

Заклучение

Однозначного ответа на вопрос, поставленный в качестве эпиграфа к этой статье, пока не существует. Однако, с уверенностью можно сказать, что полное алгоритмическое решение задачи расстановки недостающих точек над «Ё» наступит не ранее, чем в полной мере будут решены проблемы морфологического, синтаксического, семантического и прагматического анализа текстов. Например, как понять: **ВСЁ ДЕРЬМО**, или **ВСЕ ДЕРЬМО**? Система «ЭТАП» говорит, что **ВСЁ**.

В заключение хочу выразить искреннюю благодарность **Елене Ягуновой** за предоставление словаря омографов [2] и за подсказку использовать в работе Интернет ресурс [3]. И, наконец, но не в последнюю очередь, **Леониду Иомдину** за предоставленную мне возможность использования синтаксического анализатора «ЭТАП-3» в ходе выполнения данной работы.

Список литературы

1. Д.Э. Розенталь, М.А. Теленкова. Словарь-справочник лингвистических терминов // Изд. «Просвещение», М. 1976, 543 с..
2. А.В. Венцов и др. Словарь омографов русского языка // Изд. СПбГУ, Санкт-Петербург, 2004, 160 с.
3. Национальный корпус русского языка “Поиск по акцентуированному корпусу” // Интернет ресурс: <http://www.narusco.ru>
4. И.М. Богуславский, Л.Л.Иомдин, Д.Р. Валеев, В.Г. Сизов. Синтаксический анализатор системы ЭТАП и его оценка с помощью глубоко размеченного корпуса русских текстов // Труды Международной конференции <Корпусная лингвистика -2008>. СПб.: Санкт-

Петербургский государственный университет, 2008. С. 56-74.