

Федеральное государственное автономное
образовательное учреждение
высшего образования
«СИБИРСКИЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»

Институт математики и фундаментальной информатики

Базовая кафедра вычислительных и информационных технологий

УТВЕРЖДАЮ
Заведующий кафедрой
 **В.В.Шайдуров**

« ____ » 2017 г.

МАГИСТЕРСКАЯ ДИССЕРТАЦИЯ

ИССЛЕДОВАНИЕ СТАТИСТИЧЕСКХ СВОЙСТВ СИМВОЛЬНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ ПО НАБОРАМ НАИКРАТЧАЙШИХ «ПОТЕРЯННЫХ» СТРОК

Направление 02.04.01 Математика и компьютерные науки

Магистерская программа 02.04.01.02 Вычислительная математика

Научный руководитель

к.ф.-м.н., доцент



М.П. Варыгина

Выпускник



Ю.О. Якубайлик

Красноярск 2017

Аннотация

В генетике с точки зрения математика ДНК – это последовательность нуклеотидов, представленных в виде символьной последовательности. Символы представляют азотистые основания. Была написана программа поиска символьных последовательностей, отсутствующих в ДНК. Обработано более 400 нуклеотидных последовательностей, представляющих гены организмы разного таксономического положения: от бактерий до человека.

Ключевые слова: потерянная последовательность ДНК, таксономия.

In genetics, mathematics thinks that DNA is a sequence of nucleotides, represented as a character sequence. Characters represent the nitrogen bases. A program developed to search character sequences that avoided in DNA. Processed more than 400 nucleotide sequences representing the genomes of organisms of different taxonomic position: from bacteria to human.

Keywords: the lost DNA sequence, taxonomy.

СОДЕРЖАНИЕ

Введение.....	4
Глава 1.....	6
Глава 2.....	8
Глава 3.....	10
Список использованных источников.....	36
Приложение А.....	37

ВВЕДЕНИЕ

В генетике существует три точки зрения на понятие ДНК. С биологической точки зрения ДНК представляет собой макромолекулу, обеспечивающую хранение, передачу из поколения в поколение и реализацию генетической программы развития и функционирования живых организмов. С химической точки зрения ДНК — это длинная полимерная молекула, состоящая из повторяющихся блоков — нуклеотидов. Каждый нуклеотид состоит из азотистого основания, сахара (дезоксирибозы) и фосфатной группы. В ДНК встречается четыре вида азотистых оснований (аденин, гуанин, тимин и цитозин). Азотистые основания одной из цепей соединены с азотистыми основаниями другой цепи водородными связями согласно принципу комплементарности: аденин соединяется только с тимином, гуанин — только с цитозином. С точки зрения математика ДНК суть последовательность нуклеотидов, представленных в виде символьной последовательности. Символы представляют азотистые основания одной из цепей.

Задач, связанных с символьными последовательностями, можно придумать очень много, например, выделение упорядоченности, подсчет статистики различных комбинаций символов, и т.п. Тем не менее, в этой работе будет освещено в частном порядке именно анализ ДНК. Какую бы задачу мы ни решали в связи с анализом ДНК, в конечном итоге она почти наверняка сводится к изучению частотного словаря. Носитель частотного словаря — это все символьные последовательности определенного количества символов; в данной работе назовем их словами. Если каждому такому слову сопоставить натуральное число его копий включая нуль, получится конечный словарь. А если число копий заменить на частоту их появления, то есть число копий данного слова, деленное на сумму чисел копий всех слов, то получится частотный словарь. Рано или поздно наверняка какие-то достаточно длинные слова из носителя пропадут, то есть число копий слов будет равно нулю. Назовем их «потерянными» словами.

Целью данной работы было выявить связи вышеназванных «потерянных» слов с таксономией, то есть положением в живом мире, и другими биологическими показателями. Предмет исследования включает в себя списки «потерянных» слов и их свойства: насколько состав списков связан с конкретными организмами (или группой организмов) и насколько он связан со специфическими (короткими) последовательностями, играющими важную регуляторную роль. Объектом являются комбинаторные и статистические свойства таких «потерянных» слов. То есть рассматривается состав слов, «потерянных» определенными последовательностями, и их таксономия.

Задачами магистерской работы были:

- написание программы, вычисляющую список «потерянных» слов,
- подбор релевантного генетического материала (геномы подходящих организмов),
- обработка этого материала, анализ полученных списков слов (их подобие у разных организмов, связь с GC-контентом и прочее) и выявление связи установленных списков потерянных слов с таксономией носителей соответствующих последовательностей.

Глава 1

Анализ частотных и статистических свойств нуклеотидных последовательностей является областью, исследований, в которой работает большое число исследователей.

Кутыркин В.А. и Чалей М.Б. ввели понятие скрытой профильной периодичности в последовательностях ДНК. В 2013 году была опубликована статья, в которой был изложен метод распознавания такого типа скрытой периодичности [1]. Этот метод основан на применении спектрально-статистического подхода (2С-подхода).

Мирошниченко Л.А. и Гусев В.Д. в 2014 году написали программу [2], предназначенную для выявления фрактальных и фракталоподобных структур в ДНК-последовательностях. Ядром таких структур являются палиндромы или комплементарные палиндромы. Программа может быть использована для анализа структуры и классификации ДНК-последовательностей. Программа написана на языке Pascal в программной среде Delphi 7.

Спангенберг В.Е., Дадашев С.Я., Коломиец О.Л., Богданов Ю.Ф. в 2011 году исследовали [3] методами компьютерного анализа связь распределения повторяющихся последовательностей (ПП) с распределением событий мейотической рекомбинации в хромосоме 1 мыши и методом гибридизации *in situ* расположение разных типов ПП относительно синаптонемного комплекса на препаратах (спредах) сперматоцитов мыши.

Но в данных публикациях нигде не упоминаются списки потерянных последовательностей ДНК. Поэтому лучше обратиться к зарубежным источникам.

Арун Рават и Юйпин Денг в 2008 году разработали метод [4], основанный на теории графов, который учитывает предположение биологии о том, что для условной сорегуляции необходимо добывать большие банки транскрипционных данных и свойства данных микромассивов. Алгоритм вычисляет взаимосвязь между генами путем преобразования дискретных

сигналов из временных рядов данных микромассивов (технология AtGenExpress).

Бейлин Хао, Хуймин Кsie, Зугуо Ю и Гуойи Чен в 1998 году задались [5] визуализацией потерянных либо недопредставленных строк в некоторых бактериальных геномах двумя способами: кластеризацией методом Гоулдена-Джексона или конструированием минимального конечного автомата, определенного набором запрещенных слов соответствующего языка.

Апробация работы была описана в испанском журнале на английском языке [6].

Задача состоит в выявлении связей потерянных слов с таксономией. Для этого нужно выделить сами потерянные слова. Это делается программой, написанной на языке C++ в среде программирования MSVisualC++ 2008. Она также преобразует файлы в форматы, удобные для рассмотрения. Листинг можно найти в приложении. Также можно выделить задачу обработки материала. Сколько времени займет программная обработка, зависит от длины минимального потерянного слова. Отметим, что это последовательная версия программы.

Глава 2

Материалы брали в EMBL-банке; традиционно, там депонируют самые хорошо секвенированные, хорошо асSEMBЛИРОВАННЫЕ и хорошо аннотированные геномы. Брали представителей разных таксономических групп. Структура этих файлов такова, что первые строки занимает заголовок, а сам геном поделен строками, в которых 6 блоков по 10 значащих символов.

Для использования таких данных надо отсечь заголовок и объединить геном в одну большую строку. После этого, если строка слишком велика, разбиваем ее на части с перекрытием, чтобы не пропустить слова на концеп-начале.

Так как мы не знаем, какие слова пропали, надо составить носитель словаря, то есть все возможные комбинации, их 4^K , где К – длина слова. Также если список длинный, делим его на части.

Для каждого файла проверяем слова каждой длины, ищем первое пропавшее слово, длина которого и будет для данного файла наименьшей длиной пропавших слов.

Проверка идет по каждому куску файла по каждому куску носителя словаря и по каждому слову. Если есть слово, записываем, что в файле оно присутствует и забываем про него. Если нет, то это тоже записываем, но запоминаем, что в этом куске файла слова нет, и переходим к следующему слову. Если кончились слова, переходим к следующему куску носителя. Если кончился носитель, переходим к следующему куску файла. Если кончился файл, то оставшиеся слова и будут нужными словами.

Программа преобразует файлы в форматы, удобные для рассмотрения, и делает это после проверки. К тому же, эту часть программы можно запустить отдельно. Основной формат – просто строка с пробелами – разделителями слов.

Формат стека с файлами появляется, когда есть папка с файлами в основном формате: выписываются все слова определенной длины, которые

принадлежат папке, все файлы, которым принадлежит конкретное слово, и количество таких файлов. И так для всех длин в папке.

Табличный формат, как следует из названия – таблица, в которой столбцы обозначают файлы, строки – слова, а в самой таблице ставится плюс, когда файлу принадлежит слово, и минус – когда не принадлежит. Данный формат реализован для слов, принадлежащих двум и более файлам.

Формат совпадений с меньшей длиной слов появляется, когда есть соседние файлы в плане длин слов формата стека с файлами. Программа проверяет файл с большим словом на наличие в нем слов из файла с меньшим словом, записывая оба, если оно есть.

При увеличении длины слова происходит показательный рост полной длины носителя.

$$q = 4^l$$

где q – полная длина носителя, l – длина слова.

Полная длина носителя длины минимального потерянного слова сопоставима с длиной последовательности. Следовательно, разумно наблюдать крайне медленный рост длины потерянных слов при увеличении длины последовательности. Но похоже, что длина потерянного слова растёт ещё медленнее. Приведённая оценка – оценка сверху.

Для каждой последовательности мы можем вычислить её GC-контент – общее число букв G и C, делённое на общую длину последовательности.

Глава 3

Обработано более 400 нуклеотидных последовательностей, представляющих геномы организмов разного таксономического положения: от бактерий до человека.

О времени выполнения надо сказать отдельно. На 9-10 символах на один файл уходит полтора часа, в то время, как на 6-7 символах за минуту программа считает примерно 50 файлов.

Установлено, что внутригеномная вариабельность списков очень велика: списки потерянных слов, определяемых для разных хромосом одного генома имеют очень малые пересечения. Это означает, что с точки зрения потерянных слов мы должны рассматривать весь геном как одно целое: если мы все хромосомы соединим в одну длинную большую последовательность, то список потерянных слов почти не изменится.

Полный список потерянных слов минимальной длины вида *Anopheles gambiae* приведен в формате стека с файлами в таблице 1.

Таблица 1 –*Anopheles gambiae*, длина потерянных слов – 10.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
aacccatagg	cm000360;	ccctcatagg	cm000360;	gacccttaga	cm000360;	gtaccgcct	cm000360;
aacctggat	cm000360;	ccctgactag	cm000360;	gacctactca	cm000360;	gtaaaggacc	cm000360;
aagactggtc	cm000360;	ccgactatac	cm000360;	gacctagtcc	cm000360;	gtaaaggcctg	cm000360;
aaggccctac	cm000360;	ccgactttagg	cm000357;	gacctatcac	cm000360;	gtacccagtc	cm000360;
aataccagtc	cm000360;	ccgagtctct	cm000360;	gaccttagat	cm000359;	gtactcaggg	cm000360;
aatcctgagg	cm000360;	ccgcatagta	cm000360;	gaccttagtc	cm000360;	gtagactcaa	cm000360;
acagtctcta	cm000360;	ccgcgactat	cm000360;	gacgccgtat	cm000360;	gtagggagtc	cm000360;
acataggccg	cm000360;	ccgctaagag	cm000360;	gacgcctgag	cm000356;	gtagggggcc	cm000360;
accataggcg	cm000360;	ccgctgagcc	cm000360;	gacgtctcac	cm000360;	gtagggtacc	cm000360;
accatagggg	cm000360;	ccggggtaac	cm000360;	gactaacggt	cm000360;	gtagggtccc	cm000360;
acccagacat	cm000360;	ccgtctaaga	cm000360;	gactaagttc	cm000360;	gtagtcaggc	cm000360;
acccatagat	cm000360;	cctaagagtgt	cm000360;	gactacgtat	cm000360;	gtagtcctca	cm000360;
accctagggt	cm000360;	cctaagggtc	cm000360;	gactagaggt	cm000360;	gtagtcgtcg	cm000358;
accctagttc	cm000360;	cctaagtacg	cm000360;	gactagccta	cm000360;	gtatagacct	cm000360;
acctaatacg	cm000360;	cctaagttag	cm000360;	gactaggctg	cm000360;	gtatccccct	cm000360;

Продолжение таблицы 1.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
acctagtgc	cm000360;	cctaagttag	cm000360;	gactaggcc	cm000359;	gtatgatccc	cm000360;
acctgcatag	cm000360;	cctacttaaa	cm000360;	gactagtct	cm000360;	gtcagagggg	cm000360;
accttagtcg	cm000360;	cctagactcc	cm000360;	gactatagcg	cm000360;	gtccacgtct	cm000360;
accttatgcc	cm000360;	cctaggaccc	cm000356;	gactatagtc	cm000360;	gtcccctagg	cm000360;
acgagcatag	cm000360;	cctaggcaact	cm000360;	gactatgcgc	cm000360;	gtccccttga	cm000360;
acgagttacc	cm000360;	cctaggcctt	cm000360;	gactatgggg	cm000360;	gtccgttagc	cm000360;
acgcataggg	cm000360;	cctaggctaa	cm000360;	gactccgcgt	cm000360;	gtccgttac	cm000360;
acgcctataa	cm000360;	cctagggaca	cm000360;	gactcctagg	cm000360;	gtcctatagc	cm000360;
acgctagtc	cm000360;	cctagggat	cm000360;	gactcctatg	cm000356;	gtcgcaactt	cm000360;
acggggcata	cm000360;	cctagggcc	cm000358;	gactctacgt	cm000360;	gtcggagacc	cm000358;
acgtctatgc	cm000360;	cctagggc	cm000358;	gactgagtcc	cm000357;	gtctaagacc	cm000360;
actaaggctc	cm000360;	cctaggtata	cm000360;	gactggctc	cm000360;	gtctaggact	cm000360;
actaggcaag	cm000360;	cctaggtccc	cm000358;	gactggtac	cm000360;	gtctccctag	cm000360;
actaggcccc	cm000360;	cctagtaccc	cm000360;	gacttagct	cm000360;	gtctgaccat	cm000360;
actaggcctg	cm000356;	cctagtctta	cm000360;	gacttaggt	cm000360;	gtctgagtag	cm000360;
actagggata	cm000360;	cctagttcaa	cm000360;	gacttgtagg	cm000360;	gtctgggcta	cm000360;
actagggct	cm000360;	cctatagacc	cm000360;	gagacccgc	cm000359;	gtcttatgac	cm000360;
actataagec	cm000360;	cctataggag	cm000360;	gagacctacc	cm000360;	gtgacctagt	cm000360;
actatagtag	cm000360;	cctataggc	cm000360;	gagactcgt	cm000360;	gtgactagac	cm000360;
actatgggtc	cm000360;	cctatgaggt	cm000360;	gagcttaggt	cm000360;	gtgactcgcc	cm000360;
actcgggggt	cm000360;	cctatgatcc	cm000360;	gagctagtc	cm000360;	gtgagcctaa	cm000360;
actctagtc	cm000360;	cctatgcgg	cm000360;	gaggactgt	cm000360;	gtgagtceta	cm000360;
actctcctag	cm000360;	cctatggcc	cm000360;	gagggctaa	cm000360;	gtgataagtc	cm000360;
agaccctacg	cm000360;	cctatggta	cm000360;	gagtaggccc	cm000359;	gtgatatccc	cm000360;
agaccctgac	cm000358;	cctcaggcc	cm000360;	gagtaccta	cm000360;	gtgccacgt	cm000360;
agaccctgta	cm000360;	cctcataggg	cm000360;	gagtgcgt	cm000360;	gtgccctata	cm000360;
agaccctgtc	cm000360;	cctcataggt	cm000360;	gagtcccc	cm000360;	gtggcatagc	cm000360;
agacctcgct	cm000360;	cctctagacc	cm000360;	gagttacccc	cm000360;	gttaggactg	cm000360;
agaccttata	cm000360;	cctctcagat	cm000360;	gatagcgtc	cm000360;	taaataggtc	cm000360;
agacggctc	cm000360;	cctctgacaa	cm000360;	gatgtcccta	cm000360;	taacccgaga	cm000360;
agacgtctac	cm000360;	cctctaagt	cm000360;	gattccctaa	cm000360;	taacccggtg	cm000360;
agactaagt	cm000358;	cctgacctct	cm000360;	gcactataag	cm000360;	taacctaggg	cm000360;
agactaggtc	cm000356;	ccttactagg	cm000360;	gccatagtcc	cm000360;	taacctcggg	cm000360;
agactagtcg	cm000360;	ccttagactg	cm000360;	gcccatagat	cm000360;	taacgtagac	cm000360;
agactatgct	cm000360;	ccttaggact	cm000360;	gcccccctagg	cm000360;	taactaggcc	cm000360;
agactcacgg	cm000358;	ccttgtaggg	cm000360;	gccctacgt	cm000360;	taactcacgg	cm000360;
agactccgct	cm000360;	cgacataggg	cm000360;	gccctagga	cm000360;	taagagtctgg	cm000360;

Продолжение таблицы 1.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
agagacctac	cm000360;	cgacccttag	cm000360;	gccctgact	cm000360;	taagggcctc	cm000360;
agagacttag	cm000360;	cgaacctagg	cm000360;	gccctcatgg	cm000360;	taagtcagac	cm000360;
agagcccta	cm000360;	cgaacctcta	cm000360;	gcccttagtt	cm000360;	taattcgggg	cm000360;
agaggccccgc	cm000360;	cgaacctaatc	cm000360;	gccgactata	cm000360;	tacatagggc	cm000360;
agcccctaag	cm000360;	cgaacctaaatc	cm000359;	gcctaaggac	cm000360;	taccaagtcc	cm000360;
agcccctagg	cm000360;	cgaacctcgat	cm000360;	gcctataactc	cm000360;	tacccagtcg	cm000360;
agcccttatta	cm000360;	cgaacctatg	cm000360;	gcctataggg	cm000358;	tacccctgt	cm000360;
agccgtcaga	cm000360;	cgaacctacct	cm000360;	gcctataaggt	cm000360;	taccctaaga	cm000360;
agcctatacg	cm000360;	cgaaccttaac	cm000360;	gcctatggc	cm000360;	taccctagg	cm000358;
agcctccta	cm000360;	cgaaccttcag	cm000360;	gcgaactcta	cm000358;	tacctaagt	cm000360;
agctaggact	cm000360;	cgaaccttacca	cm000360;	gchgacctaag	cm000356;	tacctcagtc	cm000360;
agcttaggtca	cm000360;	cgaaccttaagg	cm000360;	gchgacctatg	cm000360;	taccttagac	cm000360;
aggagaccta	cm000360;	cggccctaggc	cm000358;	gchgactatg	cm000360;	tacgaaagt	cm000360;
aggagccctc	cm000360;	cggccctatacg	cm000360;	gchgctatgg	cm000360;	tacggaccct	cm000360;
aggagtcccc	cm000360;	cggcccttatgt	cm000360;	gchgctagacc	cm000360;	tacggcgt	cm000360;
aggccctagt	cm000358;	cggcgaggcct	cm000360;	gchgctctgag	cm000360;	tacgggtcac	cm000360;
aggccctcta	cm000358;	cggctaagtgc	cm000360;	gchggtaata	cm000360;	tactgagaga	cm000360;
aggcctaagc	cm000360;	cggactatag	cm000360;	gchggtaacct	cm000360;	tacttaggag	cm000360;
aggctagtc	cm000360;	cggactatata	cm000360;	gchgtatagc	cm000360;	tagacaggc	cm000360;
agggacctat	cm000360;	cggactatag	cm000360;	gchgtctaacc	cm000360;	tagacccgca	cm000360;
agggccctat	cm000356;	cggataagag	cm000360;	gchgtctatag	cm000360;	tagacctcac	cm000360;
aggggactag	cm000360;	cgggactatg	cm000360;	gctacgt	cm000360;	tagactcgac	cm000360;
aggggtccgc	cm000358;	cgggactcag	cm000360;	gctatagacc	cm000360;	tagactcgag	cm000360;
aggggtgccc	cm000360;	cgggctcat	cm000360;	gctatagggc	cm000360;	tagacttacc	cm000360;
aggggtacctc	cm000359;	cgggctaca	cm000360;	gctcgtagac	cm000360;	tagagtaacc	cm000360;
agggtatgcc	cm000360;	cggggattc	cm000360;	gcttagactg	cm000360;	tagagttactc	cm000360;
agggtatgtc	cm000360;	cggggtacta	cm000360;	ggaaccttaa	cm000360;	tagatctacg	cm000360;
agggtctgta	cm000360;	cggggtatac	cm000360;	ggaccccca	cm000360;	tagccccctg	cm000360;
aggtagggtc	cm000360;	cgggtaccta	cm000358;	ggaccctatg	cm000356;	tagcctagg	cm000360;
aggccctac	cm000360;	cgggtcttta	cm000360;	ggacgtatgt	cm000360;	tagcctccgt	cm000360;
aggttactag	cm000360;	cgggttactc	cm000360;	ggactaaagac	cm000360;	tagcctcgac	cm000359;
agtaccccg	cm000360;	cggtctcaga	cm000360;	ggactagccc	cm000358;	taggactagc	cm000360;
agtacctagc	cm000358;	cggtcttagg	cm000360;	ggactagtc	cm000360;	taggagtcg	cm000358;
agttagacctc	cm000360;	cgtaaggcct	cm000360;	ggactcagt	cm000360;	taggccccag	cm000360;
agttagactta	cm000360;	cgtaagttcc	cm000360;	ggactccacg	cm000360;	taggcccagt	cm000358;
agttaggccta	cm000358;	cgtagaccta	cm000358;	ggactcctgt	cm000360;	taggcgaggt	cm000360;
agtcaacgagg	cm000358;	cgtagacctc	cm000360;	ggacttagtc	cm000360;	taggcgatac	cm000360;
agtcatacct	cm000360;	cgttaggcac	cm000360;	ggacttcgt	cm000360;	taggcggagc	cm000358;

Продолжение таблицы 1.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
agtccctaag	cm000357;	cgtcaagacc	cm000360;	ggagactcta	cm000360;	taggctagtc	cm000360;
agtcttaggc	cm000358;	cgtgactaca	cm000360;	ggagtcccct	cm000360;	taggctcact	cm000360;
agtacccctac	cm000360;	cgtgggggcc	cm000360;	ggagtcccta	cm000358;	tagggaccat	cm000360;
agttaccccg	cm000360;	cgttaggcct	cm000360;	ggatcttagt	cm000360;	tagggccctg	cm000360;
ataagtccgc	cm000360;	ctaagacgcc	cm000360;	ggcacctaga	cm000360;	tagggctata	cm000360;
ataccctaag	cm000360;	ctaaggaggc	cm000360;	ggccatgtga	cm000360;	taggggccta	cm000356;
atacccttagt	cm000360;	ctaaggcggg	cm000360;	ggcccgtag	cm000360;	taggggcctc	cm000360;
atacctcgec	cm000360;	ctaaggcgtc	cm000358;	ggcctatagg	cm000360;	tagggggcta	cm000360;
atacgagcct	cm000360;	ctaagggtcg	cm000360;	ggcctcatac	cm000360;	taggggtcga	cm000359;
atacggcgta	cm000360;	ctaagtacgg	cm000360;	ggcctctacg	cm000360;	tagggctta	cm000360;
atagacccgc	cm000360;	ctaagtccga	cm000360;	ggcctctag	cm000360;	taggtaaagtc	cm000360;
atagaccctc	cm000360;	ctaccttaggc	cm000360;	ggccttagga	cm000358;	taggtacccc	cm000360;
atagacgggt	cm000360;	ctacggaggt	cm000360;	ggcctctga	cm000360;	taggtactca	cm000360;
atagaggatc	cm000360;	ctagacccgc	cm000360;	ggcgatccta	cm000360;	taggtcccc	cm000358;
atagcctgcc	cm000360;	ctagacctcc	cm000360;	ggctaagcac	cm000360;	taggtccccc	cm000358;
ataggagtcc	cm000360;	ctagagtccg	cm000356;	ggctacgtag	cm000360;	taggtccctg	cm000358;
atagccctc	cm000360;	ctagataggc	cm000360;	ggctataacct	cm000360;	taggtgagtc	cm000360;
atagggccct	cm000359;	ctaggcaagg	cm000360;	ggctatagcc	cm000360;	tagtcagggc	cm000360;
atagggctc	cm000360;	ctagggccgt	cm000360;	ggctataggg	cm000360;	tagtccgagg	cm000360;
ataggtcgta	cm000360;	ctagggaccc	cm000356;	ggctcataag	cm000360;	tagtcctgtc	cm000360;
atatggggag	cm000360;	ctaggggtcc	cm000358;	gggacactag	cm000360;	tagtctgtca	cm000360;
atcaggcctc	cm000360;	ctagggtact	cm000356;	gggacctagg	cm000360;	tataactcg	cm000360;
atcatagggg	cm000360;	ctagggtccg	cm000358;	gggactagtc	cm000360;	tatacgccgt	cm000360;
atcgaggtta	cm000360;	ctaggtccct	cm000358;	gggacttcta	cm000360;	tatacgggtc	cm000360;
atctgcggtc	cm000360;	ctaggtcggg	cm000358;	gggagtccta	cm000356;	tatactcg	cm000360;
atcttagggg	cm000360;	ctagtatacg	cm000360;	gggcataagt	cm000360;	tatactggca	cm000360;
atgagtagac	cm000360;	ctagtcaggg	cm000360;	gggcataagg	cm000360;	tatagacgcc	cm000360;
atgcgtagtc	cm000360;	ctagtctcgc	cm000360;	gggcctcta	cm000360;	tataggactc	cm000360;
atggggccct	cm000360;	ctagtctcg	cm000360;	gggcctatag	cm000358;	tatagggtcc	cm000360;
caacttagtg	cm000360;	ctatagaccc	cm000360;	gggcctcaga	cm000360;	tatagtcg	cm000360;
caagatccgt	cm000360;	ctatagggcg	cm000360;	gggcgcctaa	cm000357;	tatgagggtc	cm000360;
caaggcctat	cm000360;	ctatagggtc	cm000360;	gggcgttagcc	cm000360;	tcacctaggg	cm000360;
cagacccctga	cm000360;	ctatagtcgg	cm000360;	gggcctcatag	cm000360;	tcacgggtt	cm000360;
cagagtccct	cm000359;	ctatggaccc	cm000360;	gggccttagac	cm000360;	tcacgtact	cm000360;
caggacccca	cm000360;	ctatggagt	cm000360;	ggggagtcta	cm000358;	tcagacccga	cm000360;
caggggggtc	cm000360;	ctcagaggcc	cm000358;	ggggcatgac	cm000360;	tcagagacta	cm000360;
caggtacccc	cm000360;	ctcagctagg	cm000360;	ggggctcta	cm000360;	tcagggcg	cm000360;

Продолжение таблицы 1.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
cagtcttagg	cm000358;	ctcaggagtc	cm000360;	gggtccgta	cm000360;	tcaggtctgc	cm000358;
cataaggacc	cm000360;	ctcagggggc	cm000360;	gggtctagt	cm000360;	tccagaggta	cm000360;
cataggccta	cm000358;	ctcagtggc	cm000360;	gggttaacc	cm000360;	tccctaagtc	cm000360;
catagggcac	cm000360;	ctcatagagt	cm000360;	gggtactctg	cm000360;	tccctatagc	cm000360;
catagggggt	cm000360;	ctcatgggc	cm000360;	gggtatcccc	cm000360;	tccgactagg	cm000358;
cataggtata	cm000360;	ctccctaggt	cm000358;	gggtatccta	cm000360;	tccgcctata	cm000360;
cataggtatc	cm000360;	ctccgtaggg	cm000360;	gggtcacgta	cm000360;	tcctagggga	cm000360;
cataggtcgt	cm000360;	ctcctaggcc	cm000360;	gggtcctgac	cm000360;	tctagacccg	cm000360;
catataggag	cm000360;	ctcctagtg	cm000360;	gggtccttat	cm000358;	tctagggtgtt	cm000360;
catggcgct	cm000360;	ctccttaggc	cm000359;	gggtctaacg	cm000360;	tctcacctag	cm000360;
catgtctagg	cm000360;	ctcgtaaaag	cm000360;	gggtctcaact	cm000360;	tctcatagac	cm000360;
ccaaccttag	cm000360;	ctctacgtat	cm000360;	gggttactac	cm000360;	tctcggtata	cm000360;
ccaaggccta	cm000360;	ctctagtcga	cm000360;	ggtacctaga	cm000360;	tctgagaccc	cm000358;
ccactaggct	cm000360;	ctctgacaag	cm000360;	ggtactcagg	cm000360;	tctgataaccc	cm000360;
ccagacttaa	cm000360;	ctctgagact	cm000360;	ggtactttagg	cm000360;	tctgtggact	cm000360;
ccagagactt	cm000360;	ctgagacccc	cm000356;	ggtagacccc	cm000360;	tgacataggg	cm000356;
ccaggtctcc	cm000360;	ctgaggggtc	cm000360;	ggtagtatgc	cm000360;	tgaccctca	cm000360;
ccatagacgg	cm000360;	ctgagtccgc	cm000360;	ggtataacccc	cm000359;	tgagactccg	cm000360;
ccatagggga	cm000360;	ctgggctctag	cm000358;	ggtatacggt	cm000360;	tgaggacccg	cm000356;
cccataggct	cm000360;	ctgggtatc	cm000360;	ggtataggcc	cm000360;	tgaggcgcta	cm000360;
ccccacgtag	cm000360;	ctgggtctta	cm000360;	ggtatccgc	cm000360;	tgagggacta	cm000360;
ccccctaagg	cm000360;	ctgggtacct	cm000360;	ggtatgacta	cm000360;	tgagtacccg	cm000358;
ccccctaagt	cm000360;	cttagacgga	cm000360;	ggtattactc	cm000360;	tgagtcgccc	cm000360;
cccctaaggg	cm000360;	cttagccct	cm000360;	ggtattaggg	cm000360;	tgatccgtag	cm000360;
cccctaaggt	cm000360;	cttaggaaac	cm000360;	ggtcatagac	cm000360;	tgcgacccta	cm000360;
cccctaggct	cm000360;	cttagggacc	cm000360;	ggtccatacc	cm000358;	tggcgctgac	cm000360;
cccctaggtc	cm000360;	cttaggggac	cm000360;	ggtccctact	cm000360;	tggctacta	cm000360;
cccctctatg	cm000360;	cttaggggt	cm000358;	ggtctcgagt	cm000360;	tggcttaac	cm000360;
cccgacttag	cm000358;	cttatgaggc	cm000360;	ggtctaaccc	cm000360;	tggctccta	cm000360;
cccgacttat	cm000358;	gaaccctagg	cm000360;	ggtctagcat	cm000360;	ttaacctggg	cm000360;
cccgatacg	cm000360;	gaaccctagt	cm000358;	ggtctcaatg	cm000360;	ttacgcgtct	cm000360;
cccgctctaag	cm000360;	gaagaccccc	cm000360;	ggtctcagcc	cm000360;	ttacggccga	cm000360;
ccctaatagt	cm000360;	gaataaggcc	cm000360;	ggtctccgta	cm000360;	ttacggcgta	cm000360;
ccctacgagt	cm000360;	gacagaccac	cm000360;	ggtctctagt	cm000360;	ttagggaccc	cm000360;
ccctacgtcg	cm000360;	gaccactagg	cm000360;	ggtctctata	cm000360;	ttagtctagg	cm000360;
ccctagacta	cm000360;	gaccccccag	cm000360;	ggtctgaagg	cm000360;	ttgatccccg	cm000360;
ccctagggtc	cm000358;	gaccctagat	cm000358;	ggtcttagga	cm000360;	ttgcgaactca	cm000360;
ccctagttca	cm000360;	gaccctccat	cm000360;	ggtccctga	cm000360;		

Окончание таблицы 1.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
ccctatagcg	cm000360;	gaccctcgta	cm000360;	gtaacccggt	cm000360;		

Полный список потерянных слов минимальной длины вида *Arabidopsis thaliana* приведен в формате стека с файлами в таблицах 2 и 3.

Таблица 2 – *Arabidopsis thaliana*, длина потерянных слов – 8.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
Aagcgcgc	AJ270058;	ccgcgggc	AJ270058;	gcgcaagcg	AJ270058;	gggcccgc	AJ270058;
Acccccgcg	AJ270058;	ccggccgc	AJ270058;	gcgccaga	AJ270058;	gggcccgt	AJ270058;
Accccgggg	AJ270058;	cctacgac	AJ270058;	gcgcccc	AJ270058;	gggcgcct	AJ270058;
Acgcgcga	AJ270058;	cctggggc	AJ270058;	gcgccccg	AJ270058;	gggcgcgc	AJ270058;
Acgtgcgc	AJ270058;	cgcacgga	AJ270058;	gcgccccg	AJ270058;	gggcggta	AJ270058;
Agcccccg	AJ270058;	cgcggggc	AJ270058;	gcgccccg	AE005173;	ggggcccg	AJ270058;
Agcgcgcg	AJ270058;	cgcggcg	AJ270058;	gcgcgacc	AJ270058;	ggggccgc	AJ270058;
agcgaaaa	AJ270058;	cgcggcg	AJ270058;	gcgcgccc	AJ270060;	ggggcgcc	AJ270058;
Agggccccc	AJ270058;	cgcggcg	AJ270058;	gcgcgccg	AJ270058;	ggggcccg	AJ270058;
Agggcccg	AJ270058;	cgcggcg	AJ270058;	gcgcgccg	AJ270058;	ggggccgc	AJ270058;
Agggccgt	AJ270058;	cgcgcgt	AJ270058;	gcgcggt	AJ270058;	ggggcgtc	AJ270058;
agggcgcg	AJ270058;	cgcgcgt	AJ270058;	gcgcgtag	AJ270058;	ggggggcc	AJ270058;
agggggcc	AJ270058;	cgcgcgt	AJ270058;	gcgcgtag	AJ270058;	gggggggc	AJ270058;
Agggggta	AJ270058;	cgcgcgt	AJ270058;	gcgcgccg	AJ270058;	gtgcgcga	AJ270058;
Atacgcgg	AJ270058;	cggcgccc	AJ270058;	gccccccc	AJ270058;	gtcccccg	AJ270058;
Atcgcccg	AJ270058;	cggcacgc	AJ270058;	gcccccg	AJ270058;	gtgcgcac	AJ270058;
caggccgc	AJ270058;	cggcccc	AJ270058;	gccccgg	AJ270058;	ttacgcgc	AJ270058;
Cagggccc	AJ270058;	cggggcgc	AJ270058;	gccccgg	AJ270058;	tacgcgg	AJ270058;
caggccgg	AJ270058;	cggggggc	AJ270058;	gccccgg	AJ270058;	tagcggc	AJ270058;
Cccccccg	AJ270058;	cgggggtc	AJ270058;	gcccccc	AJ270058;	tagcccc	AJ270058;
Cccccccg	AJ270058;	cgtacggg	AJ270058;	gcccccc	AJ270058;	tattgcgc	AJ270058;
Cccccgac	AJ270058;	cgtgcgcg	AJ270058;	gcccccc	AE005173;	tccgcgcg	AJ270058;
Cccccggt	AJ270058;	ctgcggcc	AJ270058;	gcccccc	AJ270058;	tcgcgcgc	AJ270058;
Cccccggg	AE005172;	ctggcgcc	AJ270058;	gcccccg	AJ270058;	tcgtgcgc	AJ270058;
Cccgcggc	AJ270058;	cgtacgg	AJ270058;	gcccccc	AJ270058;	tgcccgaa	AJ270058;
Cccggcgc	AJ270058;	gacgcacg	AJ270058;	gcccccc	AJ270058;	tgcgccgc	AJ270058;
Cccggcgc	AJ270058;	gcacccc	AJ270058;	gcccccc	AJ270058;	tgcgccgg	AJ270058;
Ccctgccg	AJ270058;	gccccccag	AJ270058;	gccccct	AJ270058;	tgcgcgtc	AJ270058;

Окочание таблицы 2

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
Ccctgcgc	AJ270058;	gcccggcg	AJ270058;	ggcgcgcg	AJ270058;	ttcgcgcg	AJ270058;
Ccctgggc	AJ270058;	gccccggt	AJ270058;	ggcgcgct	AJ270058;	ttcgcggt	AJ270058;
Ccgcccta	AJ270058;	gccggcct	AJ270058;	ggggcccc	AJ270058;		
Ccgcgcgc	AJ270058;	gcctgggg	AJ270058;	ggggcccc	AJ270058;		

Таблица 3—Arabidopsis thaliana, длина потерянных слов – 9.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
aacggggcg	BA000015;	cctggccg	BA000015;	gcccccgct	BA000014;	ggcgggcag	BA000014;
acagcgggc	BA000014;	cgacccccc	BA000015;	gccccggc	BA000015;	ggcgtgcgc	BA000015;
acagggcgc	BA000014;	cgagcgcg	BA000014;	gccccgdc	BA000014;	gggccccg	BA000014;
accccccgg	BA000014;	cgaggcccc	BA000014;	gccccccgt	BA000014;	gggccccga	BA000015;
accccccgg	BA000015;	cgccccccg	BA000015;	gcccccgcc	BA000014;	gggccccgt	BA000014;
accgcgccc	BA000015;	cgccccgat	BA000015;	gccccgchg	BA000014;	gggccccg	BA000014;
accggcccc	BA000015;	cgccccgg	BA000015;	gccccgct	BA000014;	gggccccgg	BA000014;
acgccccgt	BA000014;	cgcccgcg	BA000015;	gccccgggt	BA000014;	gggccccgc	BA000014;
acgcccggc	BA000014;	cgcccgct	BA000014;	gccccggcc	BA000015;	gggcccccg	BA000015;
acgcccgggt	BA000015;	cgcccgcccc	BA000015;	gccccgtcg	BA000015;	gggccccgaa	BA000015;
acgcgcgccc	BA000014;	cgccctacg	BA000015;	gcccccccg	BA000014;	gggccccgca	BA000015;
acgcgcgct	BA000015;	cgcgcacct	BA000015;	gccccgccc	BA000014;	gggccccgccc	BA000014;
acgcgggggg	BA000014;	cgcgcacgc	BA000014;	gccccgctg	BA000014;	gggccccg	BA000015;
acgggcccc	BA000015;	cgcgcacgg	BA000015;	gccccggcg	BA000014;	gggccccg	BA000014;
acggggcccc	BA000015;	cgcgccccg	BA000014;	gcctggccg	BA000015;	gggcccccg	BA000015;
acggggcgc	BA000014;	cgcgccccg	BA000014;	gcgacgchg	BA000015;	ggggcccc	BA000014;
acggggcggt	BA000015;	cgcgccccgt	BA000015;	gcgaccgc	BA000015;	ggggccccg	BA000014;
acgggggggc	BA000014;	cgcgcgacg	BA000015;	gccccccca	BA000014;	ggggccccgc	BA000015;
acgggggggg	BA000015;	cgcgcgccc	BA000014;	gcccccccg	BA000015;	ggggccccgg	BA000015;
agcccccccc	BA000015;	cgcgcgca	BA000015;	gccccccga	BA000014;	ggggccccgt	BA000015;
agccccgccc	BA000014;	cgcgcgac	BA000014;	gccccccgc	BA000014;	ggggccccg	BA000015;
agcgcccccc	BA000014;	cgcgcgccc	BA000015;	gccccccgg	BA000014;	ggggccccgtc	BA000015;
agcgcccccg	BA000014;	cgcgcgcccc	BA000015;	gccccccgt	BA000015;	ggggccccac	BA000014;
agcgccccgg	BA000014;	cgcgcggt	BA000014;	gccccccctg	BA000015;	ggggccccg	BA000014;

Продолжение таблицы 3.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
agcgccgac	BA000015;	cgcgcctcg	BA000014;	gcccggaa	BA000015;	ggggcgccg	BA000015;
agcgccgggg	BA000015;	cgcgcgtgac	BA000014;	gccccggc	BA000014; BA000015;	ggggcgccgg	BA000014;
agcgccgcgc	BA000014;	cgcggcccg	BA000014;	gccccggg	BA000014;	gggggcccc	BA000014; BA000015;
aggcccccc	BA000015;	cgcggcctg	BA000015;	gccccgggt	BA000014;	gggggccccg	BA000015;
agggccccc	BA000014; BA000015;	cgcggggca	BA000015;	gccccgt	BA000015;	gggggccccga	BA000014;
agggcccgcc	BA000014;	cgcggggcg	BA000015;	gccccctac	BA000015;	gggggccccct	BA000015;
agggcgggg	BA000015;	cgctgcgcg	BA000015;	gccccctcg	BA000015;	gggggccccg	BA000014;
aggggccccg	BA000015;	cggacgggg	BA000015;	gccccacag	BA000015;	gggggccccgt	BA000014;
agggggcgcc	BA000015;	cggagcccg	BA000015;	gcccccacg	BA000015;	ggggggcccc	BA000015;
agggggccccc	BA000015;	cggcccccc	BA000015;	gcccccaact	BA000015;	ggggggccccg	BA000015;
agggggcgc	BA000014;	cggcccccg	BA000015;	gcccccccc	BA000014;	ggggggccccg	BA000014; BA000015;
aggggtgcgc	BA000014;	cggccccgg	BA000015;	gcccccccg	BA000014;	ggggggccccgg	BA000014;
agtgcgcgc	BA000015;	cggccgcgc	BA000014;	gccccccct	BA000014;	ggggggggcc	BA000015;
atagggcgc	BA000015;	cggccgcgc	BA000015;	gcccccccg	BA000014;	ggggggggccg	BA000015;
atagtgcgc	BA000015;	cggggccca	BA000015;	gccccgcac	BA000015;	gggggtgcgc	BA000015;
atccgtgcg	BA000015;	cggggccccg	BA000014;	gccccggc	BA000015;	gggttagcgc	BA000014;
atcgccccc	BA000014; BA000015;	cggggccct	BA000015;	gccccgt	BA000015;	gggtcccccg	BA000015;
atcgcccccc	BA000015;	cggggccgc	BA000014; BA000015;	gccccctac	BA000015;	gggtcccccg	BA000014;
atgcgcggc	BA000015;	cggggccgt	BA000014;	gccccctcc	BA000014;	gtacccccc	BA000014; BA000015;
atggggcgc	BA000014;	cggggcccg	BA000014;	gccccctcg	BA000015;	gtaggccccg	BA000015;
cacgcgggc	BA000014;	cggggccct	BA000015;	gccccgaca	BA000015;	gtagggcgc	BA000014;
cacgggcgc	BA000014;	cggggcgcga	BA000015;	gccccggct	BA000015;	gtcccccccg	BA000014;
caggccgcgc	BA000015;	cggggcgcgc	BA000015;	gccccggac	BA000014;	gtccgcgcg	BA000014;
caggccgtc	BA000014;	cggggcgtc	BA000014;	gccccgggc	BA000015;	gtccgggggg	BA000015;
cagtgcgcg	BA000014;	cggggcccc	BA000015;	gccccgggt	BA000015;	gtcgccccc	BA000015;
catagcgcg	BA000015;	cggggcccg	BA000015;	gccccgggt	BA000015;	gtcgccgg	BA000014;
cccaggggc	BA000015;	cggggccgc	BA000015;	gccccctacc	BA000014;	gtcgccccgg	BA000015;
cccccccccag	BA000014;	cggggcgac	BA000015;	gccccctacg	BA000014;	gtcgcccccc	BA000015;
cccccccggt	BA000015;	cggggcgca	BA000014;	gccccccgc	BA000015;	gtcgccccct	BA000014;

Продолжение таблицы 3.

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
ccccccggg	BA000014; BA000015;	cggggcgct	BA000014;	gcggaccgc	BA000014;	gtgcgcgct	BA000015;
ccccccgta	BA000015;	cgggggccc	BA000015;	gcggccgc	BA000014;	gtgcggcgc	BA000015;
ccccccgtc	BA000015;	cgggggcct	BA000015;	gcggcctag	BA000015;	gtgcgggac	BA000015;
cccccggcc	BA000014;	cgggggcgc	BA000015;	gcgggcccc	BA000015;	tacccccc	BA000015;
cccccgggc	BA000014; BA000015;	cggggggcgc	BA000014;	gcgggcccc	BA000015;	taccgcgcg	BA000014;
cccccggtcc	BA000015;	cgggggggc	BA000015;	gcgggcgc	BA000014;	tacgggcgc	BA000014;
cccccggtga	BA000015;	cgggggggt	BA000014;	gcgggcgcg	BA000015;	tagcgc	BA000014;
ccccctacg	BA000014;	cggggggta	BA000014;	gcggggccg	BA000015;	taggcacgc	BA000014;
ccccgcgcg	BA000014;	cggggggtg	BA000014;	gcggggcct	BA000015;	tagggcgc	BA000015;
ccccggggg	BA000015;	cgggtcccc	BA000014;	gcgggggcc	BA000015;	tagggcgc	BA000015;
ccccgggtg	BA000014;	cgtccggc	BA000014;	gcgggggtc	BA000014;	tagtgcgcg	BA000015;
ccccgtgcg	BA000014;	cgtcgcgc	BA000015;	gcgggtcgc	BA000015;	tccgcgcg	BA000014;
cccgcgcg	BA000014; BA000015;	cgtgcgc	BA000015;	gcgtacgc	BA000015;	tccgcgcg	BA000015;
cccgcgccg	BA000015;	cgtgcgc	BA000015;	gcgtgc	BA000015;	tccgcgcg	BA000014;
cccgcgct	BA000014;	cgtgcgtac	BA000014;	gcgtgc	BA000014;	tccgtgcgg	BA000015;
cccgctggg	BA000015;	ctgcccccc	BA000015;	ggacccgc	BA000015;	tccgcgcg	BA000015;
cccgggcgc	BA000015;	ctgcgc	BA000015;	ggacggcgc	BA000015;	tccgcgcg	BA000015;
cccgggcgg	BA000015;	ctgcgc	BA000015;	ggagcgcac	BA000014;	tccgcgcg	BA000014;
ccctgcgcg	BA000014;	ctgcgc	BA000015;	ggcccccc	BA000015;	tccgcgcg	BA000015;
ccgcgcgg	BA000015;	ctgcccccc	BA000014;	ggcccccc	BA000014;	tccgcgcg	BA000014;
ccgcgcgaa	BA000014;	ctggcgc	BA000014;	ggccccgg	BA000015;	tccgcgcg	BA000015;
ccgcgcggc	BA000015;	ctggcggg	BA000014;	ggccccgcag	BA000015;	tccgcgcg	BA000015;
ccgggcgc	BA000015;	ctggggcgc	BA000014;	ggccgcgc	BA000014;	tccgcgcg	BA000015;
ccgggcgc	BA000014; BA000015;	gacgggggg	BA000015;	ggccggag	BA000014;	tccgcgcg	BA000014; BA000015;
ccgggcgc	BA000014; BA000015;	gagcgc	BA000014;	ggccggca	BA000014;	tccgcgcg	BA000015;
ccgggcgt	BA000014;	gagcggggc	BA000015;	ggccggccg	BA000015;	tccgcgcg	BA000015;
ccggggcgc	BA000014;	gcaccgcgc	BA000014;	ggcgcacgg	BA000015;	tccgcgcg	BA000015;

Окочание таблицы 2

Слово	Файлы	Слово	Файлы	Слово	Файлы	Слово	Файлы
ccgggggcc	BA000015;	gcacgcgac	BA000015;	ggcgccccg	BA000014; BA000015;	tgcgcgggg	BA000015;
ccgggggggg	BA000015;	gcacgcggg	BA000015;	ggcgcccga	BA000015;	tgcggcccg	BA000014;
ccgggggggt	BA000014;	gcagggcgc	BA000015;	ggcgcgcga	BA000015;	tgcggggcc	BA000014;
ccgtcgccc	BA000015;	gcccccagc	BA000014;	ggcgcgctc	BA000015;	tggcgccccg	BA000015;
ccgtgcgcg	BA000014;	gcccccccg	BA000015;	ggcgcgccc	BA000015;	tgggcgcgc	BA000015;
cctcgggcc	BA000015;	gccccccgg	BA000015;	ggcgcggtt	BA000014;		
cctgcgcgc	BA000015;	gccccccgt	BA000015;	ggcgcgttc	BA000014;		
cctggcgcc	BA000014;	gcccccgat	BA000014;	ggcgcccc	BA000014;		

Полный список потерянных слов минимальной длины некоторых хлоропластов приведен в формате стека с файлами в таблицах 4, 5 и 6. Ввиду большого количества файлов, в таблицах 5 и 6 будет отражаться их количество.

Таблица 4 – хлоропласти, длина потерянных слов – 5.

Слово	Файлы
cggcc	U87145;
ggccg	U87145;

Таблица 5 – хлоропласти, длина потерянных слов – 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n
aaaaat	1	ccccga	2	cgcaga	1	cgtacg	1	gccccct	1	gcgtgc	1	gggtcc	1
aaggcgc	1	ccccgc	2	cgcggcg	1	cgtccc	1	gccccga	1	gcgtgg	1	ggtccc	1
acagcgc	1	ccccgg	3	cgcgcga	1	cgtcgcc	1	gccccgg	10	gctagg	13	ggtggc	1
accccg	2	ccccctc	14	cgcggg	1	cgtcggt	1	gccccgt	1	gctcggt	1	gtaccc	1
acgcccgc	4	cccgag	1	cgcgcac	1	cgtgcc	2	gcccctc	3	gctgtg	1	gtccct	1
acgcgca	1	cccgcg	3	cgcgag	2	cgtggc	2	gccccga	1	ggacgc	1	gtccga	1
acgcgc	2	cccgct	1	cgcgat	4	cgtgggg	1	gccccgg	2	ggagcc	1	gtccgc	1
acgcgg	1	cccggc	3	cgcgca	1	cgttcg	1	gccccga	1	ggagcg	1	gtccgg	2
acggcac	1	cccggg	1	cgcgcc	1	ctaggg	1	gccccgc	13	ggcaca	1	gtcgcg	2
acgggtgc	2	cccggt	3	cgcgcg	26	ctcgca	1	gccccgg	5	ggcacc	1	gtcggc	3
acgttg	1	ccctcc	1	cgegct	1	ctcgga	1	gccccgt	1	ggccac	2	gtctcg	1
actcgc	2	ccctcg	2	cgcggc	1	ctcggg	1	gcccctc	3	ggccca	1	gtgccc	2
agcccc	1	ccgacg	1	cgcggg	4	ctggcg	1	gcccccg	14	ggcccg	1	gtgccg	2

Окончание таблицы 5

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n
agcccg	1	ccgagc	1	cgcgtt	1	ctgtgg	1	gcgaag	1	ggccct	1	gtgcgc	7
agccgg	1	ccgatc	1	cgcgtc	1	gacccc	2	gcgaga	1	ggccga	1	gtggcc	1
agcgcc	3	ccgcag	2	cgcgtg	2	gaccgc	11	gcgagg	1	ggccgc	2	gtgtcg	1
agcgcg	2	ccgcgc	6	Cgcgtc	1	gacccg	1	gcgatc	1	ggccgg	5	taaagt	1
agcggg	1	ccgcgt	2	Cgcgtt	1	gacctc	1	gcgcac	9	ggcctc	1	tatttt	1
aggccg	1	ccgcctc	1	cggacc	2	gacgcc	1	gcgcag	1	ggcctg	1	tcacgc	1
aggcgc	1	ccggac	2	cggacg	1	gacgcg	1	gcgcat	4	ggcgcc	14	tccctg	1
agggca	1	ccggcc	6	cggcag	1	gacgga	1	gcgcca	1	ggcgcg	2	tccgca	2
aggggg	1	ccggcg	8	cggccc	3	gacggc	3	gcgccg	4	ggcgct	2	tcgagc	1
atggcg	1	ccgggc	1	cggccg	2	gagagc	1	gcgcga	1	ggcgtc	3	tcgcgg	2
attaat	1	ccgggg	2	cggcgc	1	gagccc	1	gcgcbc	18	ggctcg	1	tcggac	1
cacacg	1	ccgtcc	1	cggcgt	8	gagcgg	1	gcgccg	5	ggctct	1	tcggcc	1
cacgca	1	ccgtgt	1	cgggag	1	gaggcc	2	gcgctg	4	gggacc	1	tcgggg	1
cacggg	2	ccttagc	13	cgggca	1	gaggcg	1	gcgctg	2	gggact	2	tctcgg	1
cagagc	1	cctcgg	2	cggggc	2	gagggc	1	gccccc	2	gggagc	1	tgcggg	1
cagcgc	2	cgacgc	4	cggggg	1	gcacag	1	gccccg	2	gggccc	5	tgcggc	1
caggcc	1	cgagcg	1	cggggt	2	gcacgg	1	gccccg	5	gggcgc	13	tggccc	1
catgca	2	cgaggc	1	Cggctt	1	gccacc	1	gccccg	5	ggggcg	12	tggcgc	1
ccacgg	1	cgagtg	1	Cggta	1	gccacg	1	gcttcc	1	gggggg	2	tgggcc	3
cccacg	1	cgatag	1	Cggtgc	1	gccatc	1	gcttgc	1	ggggtc	7	tgtccg	1
cccccc	9	cgatcg	3	Cggtgt	1	gccccg	4	gcttga	1	ggggtg	1		

Таблица 6 – хлоропласти, длина потерянных слов – 7.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n
aaacacg	1	aggcgcg	44	ccgatct	4	cgtccgt	34	gcagcgg	4	ggcgtcc	9	tagcgac	5
aaaccgg	7	aggcggc	59	ccgatgc	1	cgtcccta	4	gcagcgt	50	ggcgtcg	19	tagcgag	13
aaacgcc	21	aggcggt	1	ccgatgg	3	cgtcctg	4	gcagctc	5	ggcgtct	24	tagcgca	28
aaacgca	1	aggctcc	2	ccgatgt	1	cgtcgac	1	gcaggac	1	ggcgtga	6	tagcgcg	64
aaacggc	4	aggctgg	1	ccgcaac	1	cgtcgca	22	gcaggag	1	ggcgtgc	2	tagcgct	69
aaacgtg	2	aggctgt	15	ccgcaga	11	cgtcgcc	6	gcagggc	3	ggcgtgg	4	tagcgga	7
aacacac	1	agggacc	1	ccgcagc	1	cgtcgcg	96	gcagggc	4	ggcgtgt	67	tagcgta	56
aacaccc	49	agggcac	66	ccgcatg	2	cgtcgcc	26	gcaggtg	47	ggcgttg	20	tagcgtc	11
aacaccg	8	agggccc	1	ccgcatt	1	cgtcggg	18	gcagtcc	13	ggcgttt	6	tagcgtr	86
aacacgc	47	agggcga	5	ccgcaa	1	cgtcggt	54	gcagtcg	28	ggctacc	1	tagcgtr	61
aacacgt	10	agggcgc	1	ccgcccac	1	cgtctaa	1	gcagtct	1	ggcttagc	19	taggacg	42
aacactc	1	agggcgg	4	ccgcctt	3	cgtctac	47	gcagtgt	5	ggctcca	15	taggccc	57
aacactg	45	agggtcg	12	ccgccga	1	cgtctag	3	gcatact	2	ggctctg	2	taggcgg	1

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
aacagcg	23	aggggac	1	ccgcccgc	12	cgtctcc	1	gcatagt	5	ggctgcc	86	taggcta	7		
aacagtg	5	aggggtt	1	ccgcccgg	15	cgtctcg	5	gcatccg	1	ggctgcg	25	taggctc	1		
aacatcg	4	agggtac	2	ccgcctc	1	cgtctgc	12	gcatcgt	16	ggctggc	22	tagggac	36		
aaccgcc	3	agggtag	4	ccgcctt	1	cgtctgg	9	gcatgac	1	ggctggg	4	tagggcc	5		
aaccgca	9	agggtca	1	ccgcgac	43	cgtctta	6	gcatgcg	17	ggctggt	1	tagggcg	51		
aaccggc	35	agggtcc	1	ccgcgag	6	cgtcttc	35	gcattag	1	ggctgtg	1	taggggg	35		
aaccgtc	1	agggtgc	1	ccgcgat	7	cgtgaca	1	gcattcg	17	ggcttaa	24	taggtcg	2		
aaccgtt	1	agggtgt	4	ccgcgca	2	cgtgacg	20	gccaaact	1	ggcttgc	2	taggtga	23		
aacgaca	7	aggtacg	10	ccgcgcc	31	cgtgact	8	gccacac	1	gggaagc	5	tagtcct	9		
aacgcag	5	aggtatg	1	ccgcgcf	4	cgtgagt	14	gccacag	2	gggacac	8	tagtcgc	2		
aacgccc	76	aggtcac	15	ccgcgct	70	cgtgata	6	gccacca	7	gggaccg	38	tagtcgg	1		
aacgcct	7	aggtcag	2	ccgcggg	5	cgtgatc	9	gccaccg	4	gggacct	2	tagtcgt	42		
aacgcga	6	aggcccc	1	ccgcgta	25	cgtgcac	61	gccacga	18	gggacgc	37	tagtctg	13		
aacgcgc	4	aggtcga	2	ccgcgtc	30	cgtgcca	77	gccacgc	6	gggacgt	8	tagtgc	9		
aacgcta	26	aggtcgc	15	ccgcgtt	1	cgtgccc	4	gccacgg	80	gggacta	2	tagtgcg	1		
aacggcc	7	aggtagc	3	ccgcctag	12	cgtgcga	5	gccacgt	5	gggactc	1	tagtggc	1		
aacgggc	8	aggtagt	4	ccgcgtc	1	cgtgcgc	99	gccacta	1	gggagac	15	tatacgc	11		
aacggta	7	aggtaggg	2	ccgcgtgg	66	cgtgcgg	2	gccagac	32	gggcaac	7	tatagcg	2		
aacgtca	5	aggttac	13	ccgctgt	6	cgtgcgt	71	gccagcc	67	gggcaca	59	tatcacg	38		
aacgtgc	29	aggttgc	3	ccggacg	1	cgtggca	31	gccagcg	2	gggcacc	10	tatcgca	14		
aacgtgg	11	agtacac	7	ccggact	35	cgtggcc	36	gccagct	1	gggcacg	1	tatcgcg	48		
aacgtgt	4	agtacgc	8	ccggcag	8	cgtggcg	48	gccaggc	6	gggcagc	7	tatgacg	46		
aacgtta	5	agttaggg	27	ccggcat	13	cgtgggc	8	gccaggg	2	gggcagt	2	tatgccg	29		
aactgac	1	agtatgc	2	ccggcca	6	cgtgggg	1	gccaggt	1	gggccac	46	tatgca	5		
aactgcc	2	agtacaca	1	ccggccc	19	cgtggta	37	gccagta	2	gggccca	7	tatgcgc	2		
aactgcg	13	agtacc	1	ccggccg	30	cgtggtc	5	gccagtc	46	gggccgc	12	tatgtcg	1		
aactggc	5	agtacag	3	ccggcct	55	cgtgtaa	1	gccagt	1	gggcctc	1	tatgtgc	1		
aagacac	1	agtacgc	18	ccggcgc	99	cgtgtag	2	gccatcg	3	gggcgea	12	tattcgc	9		
aagacgc	6	agtccac	1	ccggcgg	5	cgtgtca	4	gccatgt	11	gggcgcc	12	tattgcg	1		
aagccgc	1	agtccgg	90	ccggcgt	45	cgtgtcc	4	gccatta	1	gggcgct	1	tcaagcg	40		
aagcgac	1	agtgcac	1	ccggcta	10	cgtgtcg	34	gcccacc	1	gggcggc	55	tcacagt	4		
aagcgcc	1	agtgcgc	62	ccggctg	27	cgtgtgc	4	gcccact	3	gggcggg	14	tcaccca	5		
aagcgcg	9	agtgcgt	1	ccgggag	2	cgtgtgg	1	gcccatic	1	gggcgtc	57	tcaccgt	2		
aagcgcc	9	agtgcgt	3	ccgggat	1	cgtgttg	10	gccccac	4	gggcgtg	1	tcacctg	1		
aagcggt	1	agtgcgc	55	ccgggct	4	cgttaaa	14	gcccccg	5	gggcgtac	37	tcacgca	30		
aaggagc	1	agtgcgt	2	ccggggt	49	cgttaac	3	gccccct	6	gggcgtag	6	tcacgcc	57		
aaggcaa	4	agtctaa	4	ccgggtc	1	cgttacc	3	gccccgc	5	gggcgtcc	1	tcacgca	63		
aaggcca	1	agtctac	1	ccgggtg	3	cgttagg	9	gccccac	8	gggcgtc	1	tcacggt	4		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
aaggccg	6	agtctag	4	ccggtcc	5	cgttagt	3	gcccgt	3	ggggaca	1	tcacgt	25		
aaggcgc	8	agtctgc	11	ccggtcg	6	cgttcag	79	gcccgcc	10	ggggacg	11	tcactgt	6		
aaggctg	1	agtctgt	14	ccggtct	9	cgttgac	2	gcccgcg	10	ggggcca	5	tcagagg	1		
aagttag	4	agtcttg	1	ccggtgc	41	cgttgcc	5	gcccgt	15	ggggccg	7	tcagatg	1		
aagttag	1	agtgacc	1	ccggtaa	7	cgttggg	2	gcccggc	11	ggggct	5	tcagccg	30		
aagttag	1	agtgacg	2	ccgtaca	1	cgttgc	5	gcccgtt	71	ggggcgg	15	tcagcga	26		
aagttag	1	agtgagg	1	ccgtacc	1	cgttgt	1	gcccgt	16	ggggcgc	4	tcagcgt	77		
aagttag	9	agtgcac	70	ccgtata	1	cgtttaa	5	gcccgtt	1	gggg tac	20	tcagcta	3		
aatcacc	1	agtgcca	9	ccgtcca	3	cgttgc	9	gcccgt	46	ggggtgt	7	tcaggac	1		
aatcgcg	2	agtgcct	1	ccgtcta	6	ctaaacg	1	gccccta	1	gggtaac	6	tcaggtg	3		
aatctcg	1	agtgcga	1	ccgtctg	14	ctaacac	12	gcccctc	6	gggtacg	6	tcaggtt	1		
aatgcac	1	agtgcgc	109	ccgtgcc	2	ctaacag	1	gcccctg	1	gggtatg	31	tcagtag	1		
aatgcgc	17	agtggca	1	ccgtgcg	36	ctaaccg	2	gcccgt	7	gggtcac	5	tcagtgc	6		
aatggcg	35	agtggcc	1	ccgtgct	1	ctaacgg	29	gcccggc	9	gggtccg	8	tcatcgc	4		
acaacac	17	agtggc	1	ccgtggc	22	ctaacgt	10	gcccggc	56	gggtgcg	26	tcatcgc	36		
acaaccc	1	agtgggt	6	ccgtggt	1	ctaaccg	2	gcccggc	4	gggtggg	5	tcatgtg	1		
acaagac	8	agtggtc	13	ccgtgta	21	ctacact	2	gcccggg	43	gggtgtc	5	tccaaacg	36		
acaagcc	2	agtgtac	1	ccgttaa	5	ctacccg	1	gcccata	8	gggtgtg	16	tccagcg	1		
acacaac	5	agtgtcc	3	ccgttag	3	ctacgat	1	gcccgtc	34	ggtaact	1	tcccacc	1		
acacaca	7	agtgtcg	5	ccgttcg	5	ctacgca	6	gcccgt	4	ggtacac	2	tcccagc	5		
acacagt	24	agtgtgc	4	ccgttgc	11	ctacgct	35	gcccgtt	61	ggtacgc	84	tcccccg	1		
acaccac	5	agtgtta	11	ccgttgg	1	ctacgct	28	gcccgt	1	ggtacgg	2	tccccgc	2		
acaccat	4	agttagc	1	ccgttgt	4	ctacgtc	1	gcccgt	10	ggtaggc	69	tccccgg	1		
acaccca	4	agttagg	1	ccgttta	35	ctactca	5	gcccgt	14	ggtagtg	2	tcccagc	16		
acacccc	36	agttagt	1	cctaact	2	ctagaca	5	gcccgtt	1	ggtatgc	10	tcccgt	8		
acacccg	38	agttagc	1	cctaagc	2	ctagacg	1	gcccgtt	53	ggtcacc	5	tcccggc	5		
acaccga	4	agttagt	1	cctacac	2	ctagact	1	gcccgtt	6	ggtcacg	1	tccctac	5		
acaccgt	5	agttagt	5	cctacgg	5	ctagcac	39	gcccgtt	33	ggtact	2	tccctcg	7		
acacctg	66	ataaacac	11	cctacgc	6	ctagct	4	gcccgt	2	ggtact	12	tccctgc	4		
acacgac	1	ataacgt	1	cctagac	6	ctagcgc	70	gcccgt	79	ggtcatc	5	tccgagc	1		
acacgca	2	ataaccg	1	cctagcg	9	ctagcgg	37	gcccgt	17	ggtccac	1	tccgagg	2		
acacgcc	102	ataacgc	1	cctagtc	18	ctagct	93	gcccgt	59	ggtcccc	13	tccgcac	4		
acacgct	3	ataaccg	2	cctagtg	7	ctaggac	1	gcccgt	16	ggtccct	6	tccgcga	4		
acacgct	6	ataactcg	1	cctatgc	1	ctaggcc	8	gcccgt	1	ggtccgc	16	tccgcgc	17		
acacggt	13	atacccg	1	cctcacc	1	ctaggct	7	gcccgt	98	ggtccgt	6	tccgcgg	8		
acacgta	18	ataccgc	78	cctcagc	4	ctaggcc	5	gcccgt	83	ggtgcac	24	tccggac	2		
acacgtg	1	ataccgt	3	cctcaact	4	ctaggct	42	gcccgt	4	ggtgcag	6	tccggcc	7		
acacgtt	25	ataccgc	11	cctcaga	1	ctaggtag	3	gcccgg	1	ggtgcgc	12	tccggcg	4		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	N								
acactac	6	atatcg	24	cctcagt	1	ctagtc	6	gccgggc	12	ggtcg	6	tccgtcg	1		
acactag	2	atcaccc	13	cctcatc	2	ctagtc	1	gccgggg	18	ggtcg	43	tccgtct	1		
acactca	35	atcacga	2	cctccgt	1	ctagtc	2	gccgggt	60	ggtcggg	15	tccgtgc	1		
acactcg	1	atcacgc	4	cctcgac	1	ctatcgc	5	gccggta	3	ggtcggt	1	tccgttg	1		
acactgc	9	atcacgt	16	cctcgca	44	ctatgca	2	gccggtt	1	ggtcgtc	36	tcctcac	6		
acactgt	29	atcccg	1	cctcgct	35	ctatggc	1	gccgtca	3	ggtctag	6	tcctgca	1		
acagact	4	atccgca	1	cctcgga	1	ctcaact	1	gccgtcc	81	ggtctca	1	tcctcg	1		
acagaga	5	atccg	5	cctcg	6	ctcacac	2	gccgtct	10	ggtctcg	3	tcctgtc	31		
acagatg	1	atcgccc	4	cctcgta	1	ctcacag	2	gccgtgc	2	ggtctgc	6	tcctgtg	5		
acagcag	2	atcgct	1	cctgacc	1	ctcacat	5	gccgtgg	9	ggtgaca	5	tcgacac	7		
acagcct	27	atcg	60	cctgagt	37	ctcacg	12	gccgtgt	6	ggtgact	6	tcgac	14		
acagcga	1	atcg	30	cctgcaa	1	ctcacgc	22	gccgtta	4	ggtgagc	2	tcgactg	57		
acagcgc	13	atcg	6	cctg	10	ctcacgg	4	gccgttc	1	ggtgatg	3	tcgagac	20		
acagcgg	23	atcg	10	cctg	62	ctcac	6	gccgttg	1	ggtccc	34	tcgagc	1		
acagcgt	74	atcg	25	cctg	1	ctcagac	5	gccta	1	ggtccg	3	tcgagg	1		
acagctg	1	atcg	5	cctg	5	ctcagc	1	gcctaca	4	ggtgc	17	tcgcaca	1		
acaggcc	2	atcg	19	cctg	1	ctcaggc	20	gcctacc	36	ggtgc	94	tcgcaga	1		
acaggcg	1	atctac	9	cctg	40	ctccgc	3	gcctatc	1	ggtggc	7	tcgc	76		
acagggc	8	atctcg	1	cctg	8	ctccgt	1	gcctcag	1	ggtggcc	79	tcgcagg	3		
acagtaa	4	atctgca	4	cctg	3	ctcccta	2	gcctcg	57	ggtggga	5	tcgcata	1		
acagtcc	6	atgac	51	cctg	6	ctccctg	3	gcctcgg	12	ggtggc	1	tcgc	7		
acagtcg	4	atgcaca	16	cctg	2	ctcccg	13	gcctcg	6	ggtgggg	1	tcgc	1		
acagtga	1	atgcact	1	cctg	1	ctccggc	5	gcctctc	5	ggtggta	37	tcgc	59		
acagtgc	5	atgccc	1	cctg	2	ctcgaca	2	gcctgag	28	ggtggc	1	tcgc	1		
acagtgg	58	atgccc	1	cctg	2	ctcgacc	1	gcctcg	108	ggtgc	1	tcgc	1		
acagtgt	27	atgccc	2	cctg	14	ctcgact	4	gcctcg	1	ggtgtct	12	tcgc	3		
acatcag	5	atgccc	23	cctc	3	ctcgagg	1	gcctggc	7	ggtgtga	5	tcgc	47		
acatcgc	7	atgcgaa	2	cctt	10	ctcgagg	1	gcctgt	7	ggtgtgc	2	tcgc	23		
acatcg	1	atgcgac	43	cgaac	7	ctcgaa	2	gcctaa	1	ggttcac	1	tcgc	51		
acatgac	6	atgcgca	11	cgaagac	4	ctcgac	2	gccttat	3	ggttcgc	8	tcgc	62		
acatcg	3	atgcg	4	cgaagg	1	ctcgac	41	gcctca	21	ggttc	9	tcgc	1		
acatgg	3	atgcg	18	cgaat	16	ctcgat	4	gcgaacc	2	ggttc	1	tcgc	1		
accacag	63	atgcg	7	cgaaca	14	ctcg	1	gcgaagt	1	ggttggc	55	tcgc	2		
accacg	40	atgcg	1	cgaacc	6	ctcg	5	gcgaatg	10	gtaacac	42	tcgc	64		
accagcc	19	atgcg	8	cgaac	24	ctcg	1	gcgacaa	2	gtaacat	2	tcgc	4		
accagcg	1	atgcg	10	cgaac	39	ctcg	3	gcgacac	1	gtaacct	9	tcgc	8		
accagta	2	atgcg	7	cgaac	2	ctcg	49	gcgacag	14	gtacacg	67	tcgc	11		
accagt	29	atggc	3	cgaacc	6	ctcg	10	gcgacat	1	gtacact	52	tcgc	49		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
accatcg	5	atggcgc	1	cgaccag	4	ctcggac	1	gcgacca	77	gtacaga	1	tcgctgg	18		
accatgg	5	atggcgt	1	cgaccga	1	ctcggcc	1	gcgaccc	1	gtacagc	3	tcgcgt	7		
acccaca	1	atggtcg	3	cgaccgg	13	ctcggcg	17	gcgacct	15	gtacccc	36	tcgcttg	1		
acccacg	1	atggtgc	2	cgaccgt	31	ctcgggc	1	gcgacga	1	gtaccga	4	tcggact	1		
acccagc	2	atgtcat	1	cgaccta	3	ctcgta	2	gcgacgc	115	gtacccg	1	tcggagc	2		
acccagg	1	atgtcgc	5	cgacctc	46	ctcgcc	20	gcgacgg	1	gtacgac	39	tcggagg	2		
accccac	1	atgtcgt	2	cgacctg	2	ctcgctg	2	gcgacgt	116	gtacgca	56	tcggcac	2		
accccgg	36	atgtgcf	7	cgacgac	80	ctctcac	1	gcgacta	3	gtacgcc	3	tcggccg	55		
acccggc	55	atgttgc	7	cgacgca	1	ctctcgc	3	gcgactt	3	gtacgcf	110	tcggcga	6		
acccggg	60	attcgct	1	cgacgcc	16	ctctgcf	22	gcgagca	5	gtacgct	83	tcggcgc	1		
accctac	5	attgcga	1	cgacgcf	35	ctctgtc	1	gcgagcc	1	gtacgga	2	tcggcgt	44		
accctca	1	caaacgt	54	cgacgct	3	ctgaacg	18	gcgagcg	1	gtacggc	5	tcggctg	2		
accctgt	5	caaagcc	1	cgacggc	6	ctgacag	23	gcgagct	8	gtacggg	54	tcggcgc	1		
accgacg	27	caaaccg	27	cgacgta	2	ctgacct	7	gcgagga	1	gtacgfc	16	tcggggt	1		
accgagt	3	caaccgc	51	cgacgfc	46	ctgacgt	1	gcgaggc	43	gtactca	4	tcgggtg	4		
accgcat	5	caacgcc	1	cgacgtg	3	ctgactg	5	gcgagta	65	gtactcg	7	tcggtaa	1		
accgcca	26	caacgcf	66	cgactaa	12	ctgagcg	5	gcgagtg	52	gtagacg	1	tcggtgt	2		
accgcga	2	caacgct	38	cgactag	8	ctgaggg	1	gcgataa	1	gtagact	1	tcggtgt	28		
accgcgc	31	caacggc	2	cgactcg	1	ctgaggt	1	gcgatac	16	gtagcgc	9	tcgtacg	12		
accgcgg	1	caacggt	7	cgactgc	50	ctgagtc	39	gcgatag	17	gtagcgt	84	tcgtcac	5		
accgcgt	1	caacgta	8	cgactgg	1	ctgagtg	18	gcgatat	1	gtaggac	2	tcgtcat	1		
accggac	5	caacgtg	15	cgagaac	3	ctgatgc	12	gcgatca	41	gtaggca	79	tcgtctt	9		
accggcc	2	caacgtt	8	cgagacc	3	ctgatgg	1	gcgatcc	4	gtaggcg	1	tcgtcgc	1		
accggcg	5	caagcac	1	cgagacg	3	ctgcaca	75	gcgatcg	7	gtagggc	2	tcgtcgg	1		
accggct	26	caagcgc	40	cgagcat	1	ctgcacg	3	gcgatgc	1	gtaggtc	4	tcgtcta	6		
accgggc	30	caagggc	1	cgagcgg	13	ctgcaga	5	gcgatgg	4	gtagtgc	10	tcgtctg	3		
accggta	6	caatgtc	1	cgagcgt	15	ctgcagc	11	gcgatgt	20	gtatgac	1	tcgtggc	27		
accggtc	13	cacacag	62	cgagctt	1	ctgcagg	3	gcgattt	1	gtatgca	1	tctaacg	1		
accgtca	1	cacaccc	7	cgaggac	17	ctgccac	5	gcgaaa	1	gtatgcf	32	tctagcg	1		
accgtcc	8	cacacga	1	cgaggat	3	ctgcccag	87	gcgacca	72	gtatgtc	1	tctcgca	10		
accgtgg	5	cacacgc	11	cgaggcc	12	ctgcccc	4	gcfgacc	91	gtattac	8	tctcgcc	3		
accgtgt	31	cacacgg	5	cgaggcg	53	ctgcccc	17	gcfgacg	33	gtcaacg	34	tctcgcc	1		
accgttc	3	cacagat	10	cgaggct	14	ctgccc	40	gcfgact	52	gtcaagc	5	tctcgfc	19		
accgttt	1	cacagcg	2	cgagggc	2	ctgccc	15	gcfgaga	9	gtcaatg	1	tctgaca	1		
acctagt	4	cacagga	36	cgagggg	14	ctgccc	1	gcfgagg	2	gtcacag	8	tctgacg	10		
acctcac	4	cacaggc	2	cgaggtg	5	ctgcca	7	gcfgata	4	gtcacat	1	tctgcac	11		
acctcag	3	cacagtc	26	cgagtgc	1	ctgccc	16	gcfgatc	99	gtcacct	1	tctgcga	1		
acctccc	1	cacagtg	89	cgagtgt	12	ctgcat	1	gcfgatg	2	gtcacga	22	tctgcgc	19		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
acctcg	2	cacagt	22	cgagtt	41	ctgcg	13	gcccatt	5	gtcacgc	111	tctgcgg	3		
acctgca	5	cacatag	2	cgatacc	1	ctgcgt	2	gccccac	84	gtcacgg	1	tctgcgt	12		
acctcg	23	cacatga	1	cgatacg	1	ctgccc	53	gccccag	40	gtcacgt	1	tctggac	14		
acctgg	1	caccaca	1	cgatacg	3	ctgcgt	30	gccccat	12	gtcactc	10	tctggcc	3		
acctgtc	18	caccacc	4	cgatcac	5	ctgcgtc	19	gccccca	1	gtcagac	44	tctggcg	3		
accttcg	24	caccagg	2	cgatccc	1	ctgcgtg	20	gcccccg	87	gtcagca	1	tgaacac	2		
acgaact	1	caccata	8	cgatcgc	2	ctggacc	14	gccccct	1	gtcaggt	64	tgaacgt	4		
acgacaa	9	caccatg	2	cgatcg	6	ctggacg	1	gccccgc	50	gtcagtc	1	tgaagcg	1		
acgacac	84	caccac	12	cgatcg	3	ctggagg	2	gccccgg	99	gtcagt	4	tgaaggc	1		
acgacag	4	cacccga	2	cgatggc	9	ctggcac	1	gccccgt	8	gtcatac	1	tgacacc	5		
acgaccg	3	cacccgc	4	cgatgt	1	ctggcag	58	gcccccta	1	gtcatag	2	tgacacg	1		
acgacgc	3	cacccgg	61	cgcaaca	9	ctggccc	1	gccccctc	5	gtcatct	1	tgacagt	1		
acgacta	12	caccctg	66	cgcaact	3	ctggccg	13	gcccctt	20	gtcatgc	11	tgaccac	1		
acgactc	1	caccgac	5	cgcaagc	43	ctggcct	7	gccccaa	4	gtccaac	16	tgaccgt	17		
acgactg	1	caccgat	9	cgcaagt	69	ctggcga	1	gccccac	95	gtccacc	1	tgacgac	5		
acgaggc	15	caccgcg	19	cgcaatc	8	ctggcgc	44	gccccat	44	gtccaga	1	tgacgca	56		
acgatcg	5	caccggc	1	cgcacac	10	ctggcgt	4	gccccca	53	gtccacg	34	tgacg	38		
acgatgt	8	caccggg	1	cgcacag	5	ctggtag	5	gccccgg	44	gtcccac	16	tgacgct	18		
acgcaac	76	caccgtt	1	cgcacat	1	ctggct	2	gccccga	10	gtccct	1	tgacggc	3		
acgcaca	5	caccgt	16	cgcacca	6	ctggtga	1	gccccgc	36	gtccccc	11	tgacgta	1		
acgcacg	105	caccgtc	5	cgcaccc	46	ctggtgc	1	gccccgg	61	gtccctg	3	tgacgt	1		
acgcaga	77	cacctgt	4	cgcaccg	5	ctgttaag	1	gccccgt	20	gtccct	1	tgacg	5		
acgcagc	5	cacgaac	15	cgcacgc	63	ctgtacg	5	gccccgt	27	gtccctg	1	tgagacc	1		
acgcagg	85	cacgaag	51	cgcacgg	11	ctgtcac	66	gccccgtc	92	gtccctgt	3	tgagagc	1		
acgcagt	46	cacgaca	2	cgcaacta	1	ctgtcag	4	gccccgt	14	gtcccg	5	tgagcgc	41		
acgcata	7	cacgacc	1	cgcaactg	23	ctgtccg	16	gccccgtt	65	gtccgga	2	tgagcgt	1		
acgcatc	39	cacgact	13	cgcaagac	28	ctgtcgc	7	gccccata	27	gtccggc	16	tgagctc	4		
acgcatg	22	cacgatg	15	cgcaagag	58	ctgtcgg	1	gccccat	76	gtccgta	67	tgagggc	2		
acgcaa	2	cacgaa	1	cgcaagat	2	ctgtctg	5	gccccat	4	gtccgtc	2	tgagttg	10		
acgccac	20	cacgcac	72	cgcaagcc	59	ctgtgac	7	gccccat	4	gtccgtt	1	tgatgc	58		
acgcccag	3	cacgcag	66	cgcaagcg	73	ctgtgat	6	gccccat	86	gtccgtac	1	tgatgcg	53		
acgcccgg	48	cacgcat	17	cgcaaggc	77	ctgtgca	25	gccccat	6	gtccgtag	1	tgatggc	6		
acgcccga	30	cacgcca	8	cgcaagg	1	ctgtgcg	1	gccccat	5	gtccgtcg	2	tgcaacc	15		
acgcccgc	62	cacgccc	4	cgcaagg	19	ctgtggc	6	gccccat	31	gtccgtga	1	tgcaacg	1		
acgcccgg	75	cacgccc	51	cgcaagt	78	ctgtgg	11	gccccat	65	gtccgtc	1	tgcacac	4		
acgcccgt	90	cacgcct	1	cgcaagt	2	ctgtgtc	4	gccccat	15	gtccgtta	4	tgcacag	32		
acgcgaa	5	cacgcga	1	cgcatag	13	ctgtgt	17	gccccat	50	gtcgaca	2	tgacat	5		
acgcgac	23	cacgcgc	78	cgcatca	3	cttaaac	1	gccccat	5	gtcgacc	6	tgacccg	16		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
acgcgat	47	cacgccc	1	cgcaccc	38	cttaaca	1	gcggctt	54	gtcgacg	1	tgcacct	5		
acgcgca	76	cacgcgt	92	cgcaccc	17	cttaagg	9	gcggacc	18	gtcgagt	1	tgcacga	2		
acgcgcc	91	cacgcta	69	cgcaccc	5	cttaagg	2	gcggagt	7	gtcgcaa	1	tgcacgc	6		
acgcgct	102	cacgcgt	7	cgcaccc	43	cttacac	8	gcggcac	40	gtcgcat	17	tgcacgt	2		
acgcgct	2	cacgctt	30	cgcaccc	20	cttacag	18	gcggcag	10	gtcgcca	16	tgcactg	8		
acgcggc	5	cacggac	4	cgcaccc	1	cttaccg	8	gcggcca	20	gtcgccg	6	tgcagac	52		
acgcggg	33	cacggat	1	cgcaccc	6	cttacgc	1	gcggccc	16	gtcgctt	21	tgcagcc	1		
acgcggg	3	cacggca	69	cgcaccc	48	cttacgt	2	gcggcct	82	gtcgcga	2	tgcagcg	12		
acgcgtc	58	cacggcg	16	cgcaccc	49	cttagcg	13	gcggcgc	86	gtcgcgc	102	tgcaggg	3		
acgcgtg	92	cacggct	1	cgcaccc	11	cttagtc	2	gcggcgg	21	gtcgccg	33	tgcaggg	5		
acgctaa	77	cacgggg	6	cgcaccc	1	cttcagg	20	gcggcgt	88	gtcgctt	75	tgcagtt	3		
acgctac	2	cacggta	3	cgcaccc	1	cttcgca	1	gcggctt	3	gtcgcta	24	tgcacc	21		
acgctag	50	cacggtc	56	cgcaccc	38	cttcgca	3	gcggcga	24	gtcgctg	9	tgcacg	40		
acgctat	14	cacgtac	1	cgcaccc	8	cttcgtt	3	gcggcgc	4	gtcgctt	8	tgcagg	59		
acgctcg	10	cacgtag	9	cgcaccc	3	cttcgac	39	gcggcgt	2	gtcgca	9	tgcagt	12		
acgctga	1	cacgtcc	5	cgcaccc	11	cttcgca	52	gcgggga	5	gtcgccg	37	tgcacc	2		
acgctgc	5	cacgtcg	2	cgcaccc	29	cttcgct	1	gcggggc	20	gtcgcca	1	tgcacc	3		
acgctgt	77	cacgtct	1	cgcaccc	5	cttcgca	1	gcggggt	71	gtcgccg	14	tgcacc	31		
acgctta	5	cacgtga	13	cgcaccc	1	cttcgca	1	gcgggtg	28	gtcggtt	16	tgcacc	1		
acgcttc	6	cacgtta	6	cgcaccc	4	cttcgca	5	gcgggtc	12	gtcggtt	18	tgcacc	9		
acggaca	4	cacgttc	1	cgcaccc	2	cttcgtt	1	gcgggtc	22	gtcgta	9	tgcacc	1		
acggacg	56	cacgttg	3	cgcaccc	6	cttcgtt	1	gcgggtc	14	gtcgtag	5	tgcacc	1		
acggact	1	cactaac	2	cgcaccc	56	gaaacgc	1	gcgggtt	1	gtcgcc	1	tgcacc	96		
acggagt	4	cactaca	2	cgcaccc	16	gaaacgc	19	gcgggtt	8	gtcgtag	67	tgcacc	3		
acggatg	1	cactacc	1	cgcaccc	18	gaacgtt	5	gcgtaca	31	gtcgctt	42	tgcacc	13		
acggcaa	41	cactacg	6	cgcaccc	84	gaacgtt	1	gcgtacc	10	gtcgctt	17	tgcacc	1		
acggcac	6	cactagg	2	cgcaccc	36	gaacgtt	3	gcgtacc	62	gtcgctt	1	tgcacc	53		
acggcag	6	cactagt	3	cgcaccc	47	gaagccg	1	gcgtact	1	gtcgctt	1	tgcacc	19		
acggcat	16	cactcag	2	cgcaccc	5	gaagcgt	11	gcgtacc	1	gtctaca	1	tgcacc	15		
acggcct	18	cactccc	8	cgcaccc	28	gaaggcc	1	gcgtata	7	gtctaga	1	tgcacc	17		
acggcgc	3	cactccg	2	cgcaccc	1	gaagtcc	1	gcgtatc	11	gtctacc	50	tgcacc	23		
acggcgt	7	cactcgc	46	cgcaccc	14	gaatcgt	3	gcgtcaa	24	gtctacc	4	tgcacc	1		
acggcta	4	cactcgg	4	cgcaccc	3	gacaacg	18	gcgtacc	89	gtctacc	5	tgcacc	1		
acggctg	18	cactctc	19	cgcaccc	4	gacaacg	3	gcgtacc	5	gtctacc	1	tgcactt	1		
acgggac	9	cactgcc	5	cgcaccc	2	gacacac	2	gcgtatc	10	gtctacc	16	tgcacc	52		
acgggca	36	cactgca	1	cgcaccc	2	gacaccc	10	gcgtacc	1	gtctacc	1	tgcacc	1		
acgggct	9	cactggc	8	cgcaccc	1	gacaccc	5	gcgtacc	8	gtctacc	5	tgcacc	96		
acgggga	1	cactggt	6	cgcaccc	27	gacaccc	1	gcgtacc	42	gtctacc	1	tgcacc	53		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
acggtag	1	cactgtg	32	cgcctgt	5	gacacgt	2	gcgtcct	1	gtctgac	5	tgcgagg	57		
acggtca	14	cacttac	1	cgcctta	3	gacacta	3	gcgtcga	2	gtctgca	17	tgcgagt	1		
acggtcg	2	cacttcg	4	cgccttg	5	gacactt	8	gcgtcgc	95	gtctgcc	7	tgcgatc	8		
acggtct	3	cagacac	16	cgcgaaa	1	gacagac	18	gcgtcgg	45	gtctgcg	9	tgcgcaa	2		
acggtga	1	cagacag	9	cgcgaag	47	gacagcg	9	gcgtcgt	2	gtctggc	10	tgcgcac	37		
acggtgt	1	cagaccc	4	cgcgaca	25	gacaggt	1	gcgtcta	4	gtctggg	1	tgcgcat	23		
acggttg	1	cagacga	3	cgcgacc	1	gacagta	3	gcgtctc	1	gtcttag	1	tgcgccc	46		
acgtaac	6	cagacgc	5	cgcgacg	101	gacagtc	1	gcgtctt	8	gtcttcg	1	tgcgcga	48		
acgtaag	1	cagacgg	11	cgcgact	79	gacagtg	6	gcgtgaa	1	gtctta	8	tgcgcgc	49		
acgtacg	32	cagacgt	1	cgcgagt	69	gaccaca	5	gcgtgac	82	gtgaagc	3	tgcgogg	9		
acgtacg	7	cagacta	2	cgcgata	4	gaccacg	3	gcgtgag	1	gtgaagg	4	tgcgcgt	8		
acgttagt	11	cagactt	54	cgcgatg	2	gaccact	12	gcgtgat	15	gtgacaa	3	tgcgcta	1		
acgtcac	59	cagagag	17	cgcgatt	2	gaccaga	36	gcgtgcc	3	gtgacac	7	tgcgctg	87		
acgtcag	2	cagagcg	1	cgcgcaa	26	gaccagt	5	gcgtgcg	81	gtgacag	13	tgcggca	15		
acgtccg	6	cagaggc	2	cgcgcac	97	gaccccg	16	gcgtgct	21	gtgacgc	24	tgcggcc	85		
acgtctt	1	cagagt	6	cgcgcag	36	gaccctg	1	gcgtggc	39	gtgacgt	106	tgcggcg	39		
acgtcgc	56	cagatta	1	cgcgcat	8	gaccgca	35	gcgtggg	2	gtgacta	8	tgcgggg	3		
acgtcgg	59	cagcaca	64	cgcgcca	28	gaccgcc	1	gcgtggt	59	gtgagag	1	tgcggtc	21		
acgtcta	1	cagcacg	1	cgcgccg	65	gacccgc	1	gcgtgta	2	gtgagca	1	tgcgtac	28		
acgtctc	1	cagcact	1	cgcgcct	59	gaccggt	13	gcgtgtc	1	gtgagcg	86	tgcgtca	39		
acgtgac	2	cagccct	2	cgcgcga	7	gaccgta	3	gcgtgtg	5	gtgaggt	13	tgcgtcg	1		
acgtgat	2	cagccgg	26	cgcgcgc	60	gaccgtc	51	gcgtgtt	59	gtgagtg	6	tgcgtga	8		
acgtgcc	8	cagecgt	17	cgcgcgg	23	gaccgtg	57	gcgttac	5	gtgatgc	1	tgcgtgc	14		
acgtcgc	22	cagectc	1	cgcgcgt	71	gacctag	2	gcgttgc	26	gtgatta	3	tgcgtgg	60		
acgtggg	13	cagectt	1	cgcgcta	2	gacctgc	6	gcgttgg	8	gtgcaac	3	tgcgtta	5		
acgtgtc	9	cagcgaa	3	cgcgctc	3	gacctgg	2	gcgttgt	1	gtgcaag	12	tgctacg	1		
acgtgtg	1	cagcgac	10	cgcgctg	78	gaccttg	1	gcgtttc	1	gtgcaca	10	tgctac	1		
acgtgtt	2	cagcgag	74	cgcgctt	65	gacgaac	6	gcgtttg	1	gtgcacc	37	tgctcac	54		
acgttaa	5	cagcgat	4	cgcggaa	1	gacgaca	6	gcgtttt	3	gtgcacg	79	tgctcag	1		
acgttac	1	cagcgca	79	cgcggag	10	gacgacc	1	gctaaca	1	gtgcact	39	tgctcgc	1		
acgttag	37	cagcgcg	53	cgcggat	1	gacgacg	58	gctaagt	1	gtgccac	18	tgctctg	1		
acgttat	11	cagcgct	54	cgcggca	5	gacgact	29	gctaccc	3	gtgcccg	20	tgctgtc	1		
acgttca	4	cagcgcc	2	cgcggcc	5	gacgcaa	1	gctacct	1	gtgccct	42	tgctgtg	6		
acgttgc	2	cagcggg	1	cgcggcg	106	gacgcag	72	gctacgc	24	gtgccga	2	tggacac	26		
actaacg	4	cagcgta	10	cgcggga	14	gacgcat	22	gctacgt	5	gtgccgc	91	tggacgc	1		
actacac	1	cagcgtc	68	cgcgggc	7	gacgcca	2	gctagca	1	gtgcctc	16	tggacgg	6		
actaccg	1	cagcgtg	17	cgcgggg	64	gacgccc	53	gctagcc	21	gtgcgaa	1	tggactg	6		
actacgt	6	cagctgg	2	cgcgggt	14	gacgccg	37	gctagcg	97	gtgcgac	55	tggagcc	8		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
actaggc	11	cagctgt	5	cgcggtc	3	gacgcga	3	gctagtc	7	gtgcgag	2	tggaggc	2		
actaggt	1	caggaca	51	cgcggtg	1	gacgcgc	77	gctcaca	5	gtgcgca	67	tggaggg	1		
actagtg	5	caggacg	3	cgcggtt	25	gacgcgg	23	gctcacc	3	gtgcgcc	107	tggatgt	8		
actatgc	1	caggact	9	cgcgtac	32	gacgcgt	31	gctcata	2	gtgcgcg	61	tggcacg	16		
actcacg	1	caggaga	5	cgcgtag	14	gacgctc	48	gctcatc	1	gtgcgct	81	tggccac	1		
actcaga	2	caggcaa	1	cgcgtat	2	gacgctg	4	gctccga	4	gtgcgtc	4	tggccag	4		
actcagg	6	caggcag	2	cgcgtca	29	gacggac	78	gctccgg	1	gtgcgtg	91	tggcccc	8		
actcagt	2	caggcct	3	cgcgtcc	60	gacggca	64	gctcctg	5	gtgctag	1	tggccgc	86		
actccgc	2	caggcca	1	cgcgtcg	80	gacggcc	1	gctcgac	2	gtgctcc	1	tggccgg	2		
actccgg	8	cagggcg	2	cgcgtct	1	gacggcg	3	gctcgca	14	gtgctgg	26	tggccgt	1		
actcgac	1	caggggt	1	cgcgtga	12	gacggct	76	gctcgcg	1	gtgctta	26	tggcctc	1		
actcgca	8	cagggtc	2	cgcgtgc	5	gacggtc	86	gctcgct	7	gtggact	1	tggcctg	1		
actcgcg	55	cagggtg	56	cgcgtgt	1	gacggtt	3	gctcgga	1	gtggcac	9	tggcctt	4		
actcggt	4	caggtcg	1	cgcgttg	29	gacgtac	17	gctcggc	1	gtggcag	3	tggcgcac	5		
actcgtc	31	caggtta	15	cgcgttt	53	gacgtag	1	gctctag	1	gtggcca	22	tggcag	25		
actctcc	5	cagtaac	11	cgctaac	9	gacgtcc	46	gctctct	1	gtggccc	13	tggcgcc	13		
actctcg	1	cagtact	1	cgctaag	5	gacgtcg	26	gctctgc	6	gtggccg	5	tggcgcg	27		
actgacc	5	cagtagg	1	cgctaatt	1	gacgtct	19	gctgaac	38	gtggcct	12	tggcgt	51		
actgacg	18	cagtatg	2	cgctaga	2	gacgtgc	6	gctgact	47	gtggcgc	114	tggcggg	23		
actgagt	31	cagtcca	4	cgctagc	92	gacgtgt	16	gctgaga	1	gtggcgt	1	tggcgtt	9		
actgcca	2	cagtccg	15	cgctagg	12	gacgtta	28	gctgcac	26	gtgggaa	3	tggcgtc	8		
actgcc	41	cagtctt	1	cgctatc	1	gactaac	3	gctgcca	7	gtgggac	1	tggcgtg	15		
actcggt	1	cagtcta	5	cgctatg	9	gactaca	3	gctgcc	79	gtgggca	4	tggcgtt	21		
actgctc	1	cagtcgg	5	cgctcac	71	gactagc	8	gctgccc	1	gtggcgc	1	tggctgg	10		
actggca	70	cagtcta	19	cgctcga	1	gactagg	4	gctgcga	50	gtggcct	1	tgggacg	1		
actggcc	3	cagtctc	4	cgctcgc	2	gactagt	12	gctcggg	1	gtgggbc	5	tggcgc	1		
actggcg	28	cagtctg	2	cgctcgg	5	gactcag	8	gctggac	82	gtggggg	4	tgggac	7		
actggct	5	cagtgaa	1	cgctgac	5	gactccg	3	gctggca	1	gtggggt	1	tgggccc	5		
actgggt	11	cagtgcg	84	cgctgea	54	gactcgc	5	gctggct	62	gtgggtg	3	tgggta	4		
actggtc	7	cagtgtc	1	cgctgcc	6	gactctg	2	gctggga	27	gtggtac	9	tgggtac	4		
actggtg	2	cagtgtt	57	cgctcgg	92	gactgac	1	gctgggg	5	gtggta	5	tgggtgc	5		
actgtca	4	cagttag	1	cgctgga	14	gactgcc	5	gctggta	3	gtggtcg	56	tgggtgt	1		
actgtcg	66	catacgc	1	cgcttgt	1	gactgcg	59	gctgtaa	9	gtgtaa	11	tggtagg	7		
actgtgc	1	catagcg	3	cgctgtc	29	gactgct	6	gctgtac	1	gtgtacg	10	tggtcgc	82		
actgtgg	27	catcacc	6	cgctgtc	14	gactggc	21	gctgtat	3	gtgtacg	1	tggtagc	13		
actgtgt	19	catcacg	3	cgctgtg	18	gactggg	1	gctgtcc	16	gtgtagg	2	tggtgc	41		
actgtta	1	catccga	2	cgctgtt	4	gactgtg	25	gctgtga	1	gtgtagt	1	tggtgcg	55		
acttaag	4	catcett	1	cgcttaa	4	gagaact	1	gcttaaa	24	gtgtcca	26	tggtggc	53		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
actcccc	1	catcgcc	5	cgcgtga	7	gagaccc	1	gcttaag	9	gtgtccc	2	tggttgc	19		
acttgcc	1	catcgcg	11	cgcgtgc	4	gagaccg	2	gcttaca	1	gtgtcct	1	tgtaagc	1		
acttgcg	86	catcgct	8	cggaaagt	7	gagacct	1	gcttagc	1	gtgtcga	6	tgtagg	1		
agaacgc	1	catcgtc	1	cggacag	1	gagacgc	73	gcttgcg	54	gtgtcgc	5	tgtacccg	3		
agacacc	11	catcgta	2	cggacat	4	gagacgg	1	gcttggc	1	gtgtcgt	12	tgtacgc	78		
agaccac	3	catctgc	2	cggaccc	6	gagactg	4	gcttgtc	8	gtgtctg	13	tgtactc	1		
agaccag	14	catgaca	10	cggaccg	2	gagagtg	50	ggaagcc	15	gtgtctt	15	tgtagcc	1		
agacccc	1	catgcga	6	cggacga	1	gagccag	1	ggacaag	2	gtgtgag	6	tgtagcc	2		
agaccgc	83	catgcgc	3	cggacgc	65	gagcccg	1	ggacacg	17	gtgtgca	7	tgtagtc	1		
agaccgg	2	catgccc	5	cggacgt	4	gagccgc	1	ggacact	62	gtgtgcc	29	tgtcaca	1		
agacctg	1	catcggt	31	cggactc	1	gagcgag	7	ggacagc	14	gtgtgcg	21	tgtcacg	5		
agacgac	2	catgtgc	2	cggactg	64	gagcgat	6	ggacccc	14	gtgtggc	1	tgtcagg	4		
agacgca	40	ccaacag	9	cggagcg	10	gagcgcc	10	ggacccg	1	gtgtgtc	3	tgtcccc	9		
agacgcc	22	ccaacgc	58	cggaggt	7	gagcggc	48	ggaccgc	7	gtgttac	6	tgtccgg	1		
agacgcf	2	ccaacgg	1	cggagtc	5	gagcggg	1	ggacgac	35	gtgttag	12	tgtccgt	2		
agacggc	9	ccaacgt	3	cggagtg	2	gagcgta	1	ggacgag	6	gtgttcc	1	tgtccta	1		
agacggg	1	ccacacg	4	cggatgt	1	gagcgtc	88	ggacgcc	4	gtgttga	1	tgtcccg	1		
agacgtc	17	ccacagt	66	cggcaac	9	gaggaca	4	ggacgcf	80	gtgttgc	6	tgtcgac	9		
agacgtg	5	ccaccag	10	cggcaag	15	gaggacg	2	ggacgct	7	gtttaacg	33	tgtcgag	1		
agactag	2	ccaccat	1	cggcaca	60	gaggcac	2	ggacggc	90	gtttaact	1	tgtcgca	6		
agactat	1	ccaccga	3	cggcacc	2	gaggccc	2	ggacggt	5	gttacac	4	tgtcgcc	5		
agactcg	5	ccaccgt	11	cggcaact	1	gaggccg	5	ggacgta	1	gttaccg	61	tgtcgcg	47		
agactgt	4	ccacgac	3	cggcagc	9	gaggcga	6	ggacgtc	25	gttacgc	1	tgtcgct	6		
agagcga	15	ccacgca	62	cggcagg	55	gaggcgg	2	ggacgtg	3	gttagac	6	tgtcggt	2		
agagctg	2	ccacgcc	3	cggcata	13	gaggcgt	1	ggactag	9	gttagcg	25	tgtcgta	3		
agaggct	8	ccacggc	5	cggcatac	2	gaggctg	3	ggactgc	10	gttaggc	56	tgtcgtr	36		
agagtgg	1	ccacgtt	5	cggccac	13	gagggag	1	ggactgt	14	gttagta	1	tgtctgc	4		
agatgac	3	ccactac	1	cggccag	2	gagggca	2	ggagaac	1	gttagtc	2	tgtgacc	1		
agatggg	1	ccactag	6	cggcccc	31	gagggcc	1	ggagcac	4	gttcacc	1	tgtgacg	5		
agcaacg	1	ccactgt	2	cggcccg	14	gagggcg	47	ggagccc	1	gttcagc	1	tgtgagc	1		
agcaagc	10	ccagacc	7	cggccct	5	gaggggt	29	ggagcct	5	gttcgcg	9	tgtgcac	26		
agcacac	1	ccagacg	7	cggccga	35	gagggtc	1	ggagcga	1	gttcgct	5	tgtgcag	16		
agcaccg	5	ccagcac	88	cggccgg	29	gaggtca	1	ggagcgc	84	gttcggc	5	tgtgccc	2		
agcacgc	17	ccagcca	1	cggccta	60	gaggtcg	70	ggaggac	1	gttcgtg	42	tgtgccg	3		
agcacgg	1	ccagccc	1	cggcctc	15	gaggtga	4	ggaggtc	1	gttctcg	1	tgtcgga	9		
agcactt	1	ccagccg	5	cggcgca	16	gaggtgt	4	ggagggc	1	gttgatc	1	tgtgcgc	15		
agcagac	2	ccagcct	6	cggcgcc	72	gagtctg	2	ggagtca	2	gttgcac	5	tgtgctg	49		
agcagcg	10	ccagcga	15	cggcgcg	86	gagtcta	15	ggagtgc	14	gttgcag	1	tgtggcc	16		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
agcaggc	1	ccagcgc	74	cggcgct	1	gagtgac	23	ggagtgg	2	gttgcgc	2	tgtggcg	4		
agccagc	69	ccagcg	29	cggcgga	4	gagttag	4	ggatgcg	4	gttgcct	9	tgtggtc	2		
agccagt	44	ccagctg	2	cggcgta	3	gagtgcc	38	ggatgtg	5	gttgcgt	35	tgtgtag	1		
agcccag	1	ccagctt	6	cggcgtc	62	gagtgt	7	ggcaaag	1	gttggcc	3	tgtgtcc	6		
agcccga	6	ccaggac	1	cggcgta	85	gagtgtt	9	ggcaaca	1	gttggcg	6	tgtgtgc	7		
agcccgc	18	ccagget	3	cggcgtt	69	gatcacg	1	ggcaacc	4	gttgc	4	tgtgtgt	3		
agcccgg	9	ccagggt	1	cggctac	1	gatcccc	1	ggcaacg	109	gtttaag	10	tgtgttc	1		
agccctc	1	ccaggtg	1	cggctag	1	gatgc	1	ggcaagg	23	gttgc	1	tgttacc	1		
agccgat	5	ccagct	1	cggctga	16	gatggc	2	ggcaatg	1	taacacc	2	tgttagc	9		
agccgcc	1	ccagtgt	1	cggctgt	1	gatgagg	1	ggcacac	33	taaact	2	tgttcac	15		
agccggg	2	ccatcac	1	cggctta	1	gatgcc	17	ggcacca	7	taaccag	10	tgttcgg	1		
agccggt	48	cccac	3	cggcttc	1	gatgca	14	ggcac	5	taacctg	6	tgttctc	1		
agccgtc	27	cccacgc	24	cgggacg	16	gatgc	78	ggcacgc	5	taacggc	7	tgttgcc	17		
agccgtg	1	cccacgt	6	cgggca	16	gatgcgt	1	ggcacgg	4	taacggg	35	tgttgcg	16		
agcctac	9	cccac	1	cgggcac	69	gatggc	2	ggcacgt	16	taacgtc	2	tgttgc	1		
agcctag	8	cccacg	1	cgggcag	50	gatgtc	45	ggcac	1	taacgt	13	ttaacct	1		
agcctcg	22	cccac	4	cgggc	7	gatgtgt	1	ggcactt	11	taacgt	1	ttaacgg	6		
agcgaca	1	cccac	1	cgggc	33	gattgc	2	ggcagac	77	taagcac	1	ttaacgt	2		
agcgact	10	ccccac	3	cgggc	69	gcaaac	55	ggcagcc	73	taagc	2	ttaagcc	20		
agcgagc	7	ccccac	1	cgggc	5	gcaacac	5	ggcagc	10	taagcgt	6	ttaagc	15		
agcgagg	16	ccccac	5	cgggc	15	gcaacca	4	ggcagc	1	taaggc	1	ttaagt	3		
agcgatg	56	ccccac	5	cgggc	38	gcaacc	19	ggcagga	4	taaggc	2	ttacac	9		
agcgac	82	ccccac	1	cgggc	1	gcaac	12	ggcagg	4	taagt	1	ttacac	1		
agcgcat	5	ccccac	4	cgggc	4	gcaac	20	ggcagg	2	taagt	1	ttacagt	5		
agcgcca	46	ccccac	5	cgggc	10	gcaac	11	ggcatac	1	taagt	1	ttacgg	12		
agcgccc	2	ccccac	23	cgggc	24	gcaac	58	ggcatac	5	taatc	1	ttacgca	1		
agcgccg	2	ccccac	1	cgggc	1	gcaact	1	ggccaa	2	taatc	1	ttacgct	1		
agcgca	25	ccccac	2	cgggc	5	gcaac	11	ggccaca	8	tacac	10	ttacac	58		
agcgccg	76	ccccac	1	cgggc	5	gcaacaa	7	ggccacc	68	tacac	63	ttagact	2		
agcgccgt	17	ccccac	5	cgggc	3	gcaacac	1	ggccac	8	tacac	24	ttagc	10		
agcgcta	12	ccccac	50	cgggc	1	gcaacaca	1	ggccact	48	tacact	2	ttagc	19		
agcgctc	8	ccccac	5	cgggc	1	gcaacacc	61	ggccaga	17	tacact	1	ttagc	72		
agcgctg	90	ccccac	16	cgggc	9	gcaac	2	ggccagg	3	tacac	31	ttagc	8		
agcgac	1	ccccac	8	cggtaac	1	gcaact	1	ggccac	1	tacac	5	ttaggc	1		
agcgag	1	ccccac	1	cggtaac	1	gcaacaga	1	ggccca	6	tacac	1	ttagtgc	2		
agcgcc	20	ccccac	10	cggtaac	42	gcaac	1	ggcccc	26	tacac	1	ttacgc	39		
agcgccg	1	ccccac	4	cggtaac	1	gcaacagg	2	ggcccg	1	tacac	9	ttatgt	1		
agcgcccc	1	ccccac	3	cggtaac	69	gcaac	45	ggcccg	14	tacac	4	ttagc	5		

Продолжение таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
agcggtc	5	cccgctg	26	cggtccg	1	gcacatg	9	ggcccta	1	taccggc	14	ttcaactg	1		
agcgtagc	47	cccgctg	3	cggtcga	3	gcaccac	1	ggccctc	1	taccggg	11	ttcagcg	6		
agcgtag	1	cccgac	1	cggtcgc	5	gcaccat	5	ggccgag	1	taccta	1	ttcaggc	1		
agcgtagt	1	cccgca	7	cggtcta	1	gcacccc	1	ggccgat	2	tacctgc	1	ttcccg	1		
agcgta	15	cccgcc	2	cggtctc	30	gcacccg	1	ggccgca	78	tacctgg	1	ttcctgc	1		
agcgtc	6	cccgcg	7	cggtgac	1	gcaccct	1	ggccgcc	4	tacgagg	2	ttcgacg	6		
agcgtcg	3	cccgct	7	cggtgag	19	gcaccga	1	ggccgcf	6	tacgcaa	5	ttcgacac	1		
agcgtc	83	cccggt	28	cggtgca	29	gcaccgc	19	ggccgct	24	tacgcag	46	ttcgacag	9		
agcggt	48	cccgctc	5	cggtgtc	1	gcaccgg	31	ggccggc	92	tacgcat	1	ttcgcc	26		
agcgttg	3	cccgat	4	cggtgcc	4	gcaccgt	5	ggccggt	8	tacgcca	2	ttcgctg	7		
agctacc	1	cccgct	1	cggtggg	9	gcacgac	7	ggccgtt	4	tacgccc	34	ttcgcc	4		
agctcaa	1	cccgta	16	cggtgta	2	gcacgat	1	ggccta	1	tacgcga	2	ttctgcg	3		
agctcgc	15	ccctaag	2	cggtgtt	45	gcacgca	27	ggcctcg	61	tacgcgc	54	ttgaccg	4		
agctcg	1	ccctacg	5	cggttac	3	gcacgcc	8	ggcctct	1	tacgcgg	38	ttgacgc	1		
agctgcc	3	ccctact	1	cggttag	29	gcacgcf	10	ggcctgc	1	tacgcgt	6	ttgecag	1		
agctgta	9	ccctagg	5	cggttgc	5	gcacgct	59	ggccttc	5	tacgcta	22	ttgccc	3		
agctgtc	16	ccctcaa	1	cggttgg	4	gcacgga	47	ggcgacc	7	tacgctc	3	ttgccc	2		
aggacac	1	ccctcag	6	cggttgt	1	gcacggg	1	ggcgacg	6	tacgctg	29	ttgccc	8		
aggacga	26	ccctgac	5	cgttaacc	5	gcacggt	1	ggcgaga	1	tacggag	1	ttgac	13		
aggacgt	3	ccctgcg	5	cgtacac	7	gcacgct	3	ggcgagt	4	tacggca	4	ttgac	3		
aggactc	1	ccctggc	3	cgtaccc	1	gcacgtt	1	ggcgcac	42	tacggcc	4	ttgac	10		
aggactg	1	ccctggt	3	cgtacct	2	gcactaa	1	ggcgcat	6	tacggtc	1	ttgac	65		
aggactt	2	ccctgtc	1	cgtacga	8	gcactac	8	ggcgcca	13	tacggtg	1	ttgac	27		
aggagac	4	ccctgtg	4	cgtacgc	106	gcactcc	11	ggcgccc	11	tacgtag	1	ttggc	4		
aggagcg	1	cccttcg	1	cgtacgg	12	gcactcg	1	ggcgccg	80	tacgta	1	ttgggt	2		
aggatac	1	ccgaagg	5	cgtacgt	12	gcactga	5	ggcgct	65	tacgtt	2	ttgggtc	1		
aggcaac	60	ccgacaa	4	cgtagcc	5	gcactgc	6	ggcgcbc	4	tactcag	2	ttgtc	8		
aggcaag	1	ccgacag	1	cgtagtg	2	gcactgg	1	ggcgccg	34	tactcgc	52	ttgtcg	3		
aggcaca	1	ccgacat	5	cgtatcg	9	gcagaac	5	ggcgct	62	tactgac	1	ttgtctg	4		
aggcacg	1	ccgaccg	1	cgtcaac	2	gcagaca	16	ggcgctc	7	tactgcc	1	ttaagc	4		
aggcatg	2	ccgacga	52	cgtcacg	100	gcagacc	31	ggcgctt	1	tactggc	3	tttagcg	15		
aggccac	12	ccgacgc	23	cgtcact	13	gcagacg	76	ggcgag	18	tagacgg	5	tttgcc	4		
aggccag	26	ccgacgt	46	cgtcaga	3	gcagact	43	ggcgccg	61	tagactg	1	tttgcc	1		
aggccgc	86	ccgacta	45	cgtcagt	8	gcagagc	8	ggcgccg	11	tagacc	1	tttgcc	1		
aggccgg	75	ccgagca	1	cgtcata	4	gcagatg	1	ggcgccc	1	tagccg	8				
aggccgt	63	ccgagcg	27	cgtcatg	63	gcagcac	2	ggcggt	66	tagccgc	8				
aggcctg	2	ccgagct	1	cgtcccc	1	gcagccc	13	ggcggtt	4	tagccgg	1				
aggcgac	30	ccgaggc	13	cgtcccg	10	gcagcga	14	ggcgta	1	tagccta	47				

Окончание таблицы 6.

Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	n	Слово	N
aggcgcc	34	ccgaggt	4	cgtccgg	8	gcagcgc	48	ggcgtca	4	tagcctg	1				

Результаты, представленные в таблице 7, показывают крайне медленный рост длины потерянных слов при увеличении длины последовательности.

Таблица 7—перепись числа наименьших потерянных слов

ID	Организм	Длина генома	Длина наименьшего слова	Количество наименьших слов
FR775227	Salmonella enterica subsp. Mitochondrion	17569	5	2
HQ184045	Bos taurus isolate Mcg375 mitochondrion	16340	5	13
JF727176	Pan troglodytes isolate Flo mitochondrion	16557	5	13
KC469587	Sus scrofa domesticus breed pietrain mitochondrion	16612	5	12
KM061558	Canis lupus familiaris isolate Cf stp64 mitochondrion	16730	5	13
AY217738	Eimeria tenella	34750	5	4
AY945289	Fusarium oxysporum strain F11 mitochondrion	34477	5	2
DQ508940	Debaryomyces hansenii mitochondrion	29462	5	2
DQ642846	Plasmodium falciparum HB3	29529	5	92
JQ864234	Candida albicans strain L296 mitochondrion	33631	5	8
EU651892	Hemiselmis andersenii strain CCMP 644mitochondrion	60553	5	2
FR775213	Salmonella enterica subsp. enterica serovar Weltevreden	64694	6	33
FR775245	Salmonella enterica subsp. enterica serovar Weltevreden	63517	5	4
HG004427	Campylobacter fetus subsp. Venerealis	61142	5	9
KF285530	Ostreococcus tauri isolate RCC1123 chloroplast	67681	6	13
AB042240	Triticum aestivum chloroplast	134545	7	399
CP00224	Candidatus Tremblaya princeps PCIT	138927	6	3
FR775217	Salmonella enterica subsp. enterica serovar Weltevreden	131230	6	19
JN861109	Oryza sativa Indica Group cultivar Hassawi chloroplast	134448	7	361
X86563	Zea mays complete chloroplast genome	140384	7	351
CP000351	Leptospira borgpetersenii, chromosome 2	299762	7	85
CP002163	Candidatus Sulcia muelleri CARI,	276511	6	99
CP007234	Candidatus Sulcia muelleri strain TETUND	270029	6	81
FR775191	Salmonella enterica	227697	6	16

FR775236	Salmonella enterica serovar Weltevreden	253936	6	9
AY506529	Zea mays strain NB mitochondrion	569630	8	1059
CP002243	Candidatus Moranella endobia PCIT	538294	7	6

Окончание таблицы 7.

ID	Организм	Длина генома	Длина наименьшего слова	Количество наименьших слов
CP003000	Blattabacterium	587248	6	10
CP003771	Mycoplasma genitalium M6282	579504	6	11
CP006771	Mycoplasma parvum str. Indiana	564395	6	8
AL954800	H. sapiens, chromosome 14	87191216	9	110
CM000265	H. sapiens, chromosome 14	87316725	9	110
CM000856	Callithrix jacchus, chromosome 1	210400635	9	3
CM000878	Callithrix jacchus, chromosome X	142054208	9	62
CM000879	Callithrix jacchus, chromosome Y	2853901	7	4
CM000001	Canis lupus familiaris, chromosome 1	122678785	9	4
CM000002	Canis lupus familiaris, chromosome 2	85426708	9	11
CM000003	Canis lupus familiaris, chromosome 3	91889043	9	41
CM000004	Canis lupus familiaris, chromosome 4	88276631	9	63
CM000356	Anopheles gambiae str. PEST chromosome 2L	49364325	10	16
AE005172	Arabidopsis thaliana chromosome 1	14221815	8	1
AP011156	Acetobacter pasteurianus IFO 3283-32	2904642	6	490

Для бактерий показано сильное подобие потерянных слов их сайтам рестрикции. Чтобы доказать это на примере бактерии Acetobacter pasteurianus, приведу сайт рестрикции: 5'...G/TGCAC...3', [7] и участок списка потерянных слов, начинающихся с тройки гуанин-тимин-гуанин: gtgacc gtgacg gtgact gtggac gtggga gtgggtt gtgtac gtgtct gtgtta, и с тройки цитозин-аденин-цитозин: cасасг cacatg caccсс caccсг cacctc сасгас сасгга састаг састс састга састта састг. Как видно, с учетом замен, вставок и удалений, они сильно похожи.

Распределение GC-контента некоторых хромосом в виде гистограмм представлены на рисунках 1-4. По оси X гистограмм представлен собственно GC-контент, а по оси Y количество потерянных слов с указанным GC-контентом.

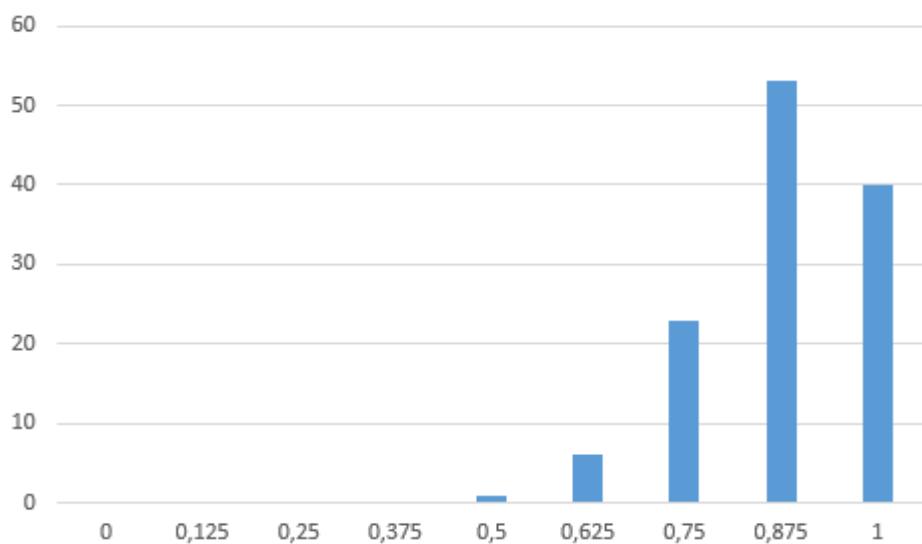


Рисунок 1 – распределение GC-контента потерянных слов длины 8 хромосомы AJ270058 (вид *Arabidopsis thaliana*).

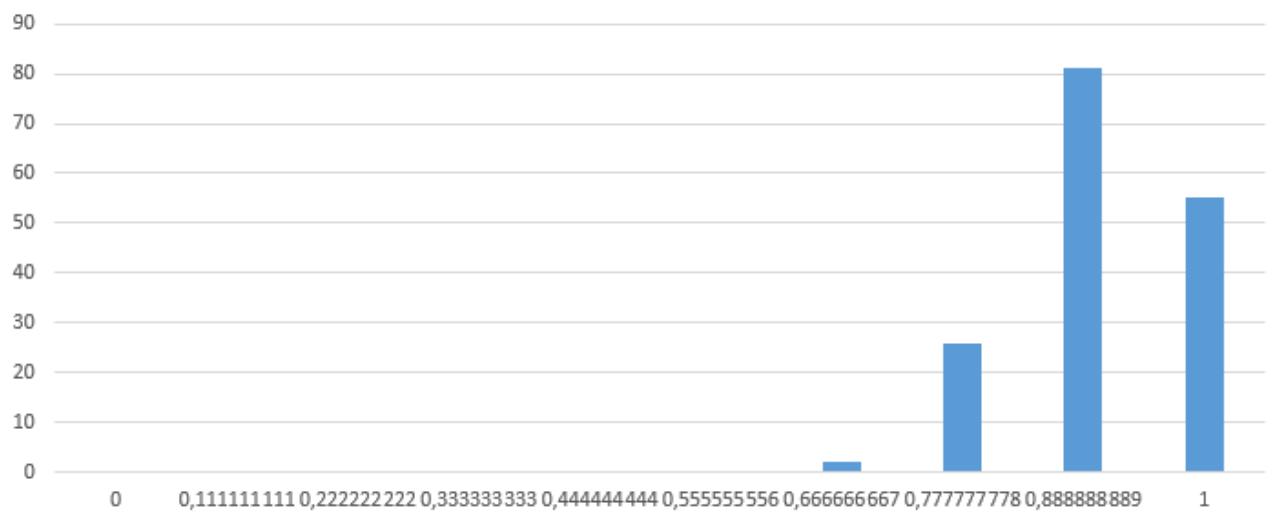


Рисунок 2 – распределение GC-контента потерянных слов длины 9 хромосомы BA000014 (вид *Arabidopsis thaliana*).

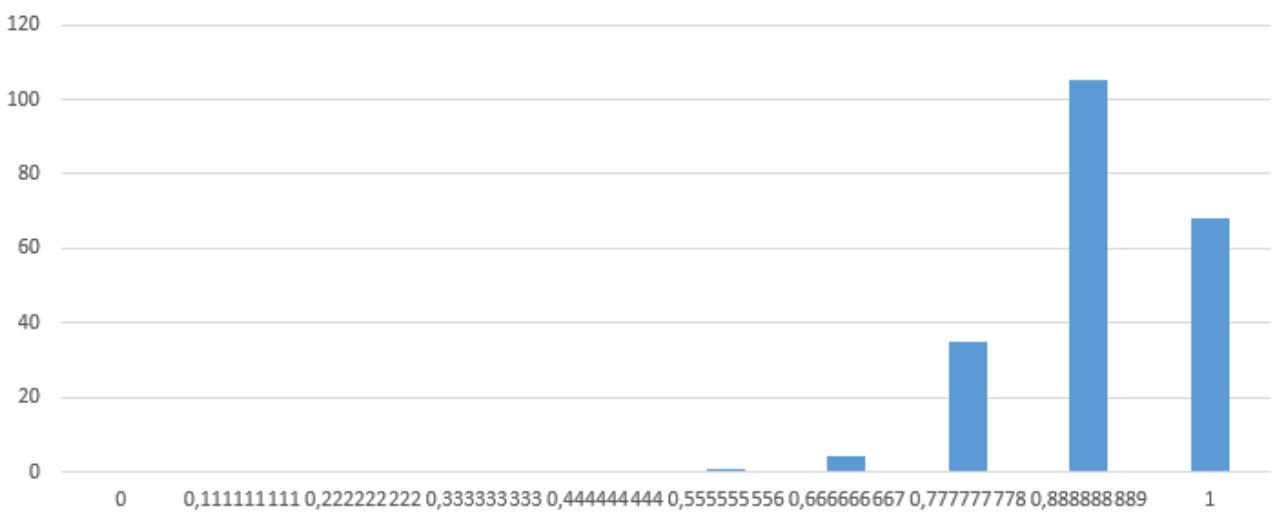


Рисунок 3 – распределение GC-контента потерянных слов длины 9 хромосомы BA000015 (вид *Arabidopsis thaliana*).

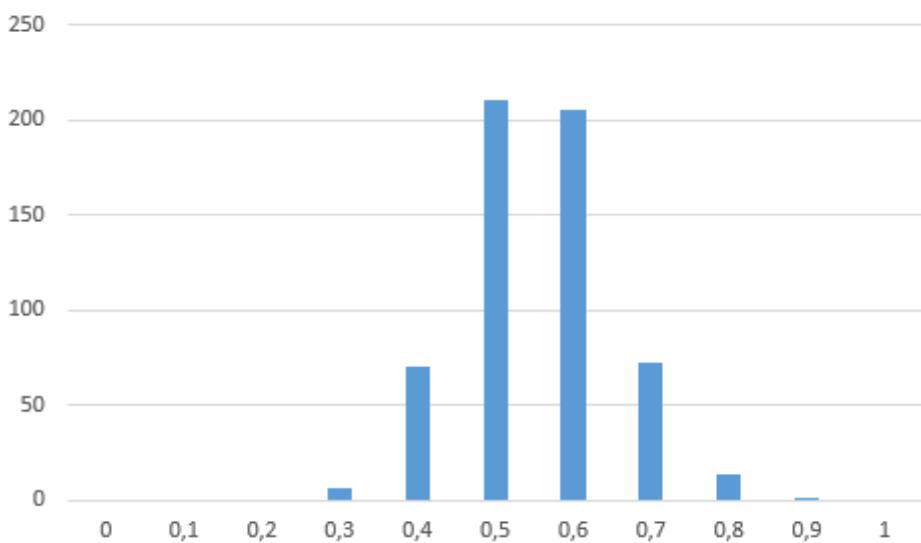


Рисунок 4 – распределение GC-контента потерянных слов длины 10 хромосомы cm000360 (вид *Anopheles gambiae*).

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Кутыркин, В.А. Распознавание скрытой периодичности в последовательностях ДНК / В.А. Кутыркин, М.Б. Чалей // Математическая биология и биоинформатика. – 2013. – Т. 8, № 2. – С. 502–512.
2. Мирошниченко, Л.А. Программа «SIM_PAT» для поиска фракталоподобных структур в ДНК-последовательностях / Л.А.Мирошниченко, В.Д. Гусев // Хроники объединенного фонда электронных ресурсов наука и образование – 2014. – № 1 (56). – С. 62.
3. Спангенберг, В.Е. Повторяющиеся последовательности ДНК могут принимать участие в формировании синаптонемных комплексов / В.Е. Спангенберг, С.Я. Дадашев, О.Л. Коломиец, Ю.Ф. Богданов // Цитология. – М., 2011. – Т. 53, № 3. – С. 235–241.
4. Rawat, A. Novel implementation of conditional co-regulation by graph theory to derive co-expressed genes from microarray data / A. Rawat, Y. Deng // BioMed Central Bioinformatics. – Oklahoma City, OK, USA, 2008.
5. Hao, B. Avoided strings in bacterial complete genomes and a related combinatorial problem / B. Hao, H. Xie, Z. Yu, G. Chen // Annals of combinatorics. – 1998(2000). – #4 – P. 247–255.
6. Sadovsky, M. Lost Strings in Genomes: What Sense Do They Make? / M. Sadovsky et al. // Strong Inhomogeneity in Triplet Distribution. – P. 20-29.
7. Сайт рестрикций бактерии *Acetobacter pasteurianus* [Электронный ресурс] – режим доступа:
http://www.skygen.com/catalog/biohimicheskie_reaktivy/new_england_biolabs/endo_nukleazy_restriktssi/standartnye_restriktazy/apali/

ПРИЛОЖЕНИЕ А

```
#include <stdio.h>
#include <tchar.h>
#include <string.h>
#include <math.h>
#include <stdlib.h>
#include <windows.h>
#include <stdlib.h>
char filepath[100];
char ifilepath[100],ofilepath[100],PathOfMatch[100],lengthResult[150];
char pathoftables[100];
const int maxfrnumber=1500000000,froverlap=100,maxwordsnumber=2000000;
int q=1,wc=0,fwc=0,orq,i,j,k,NFile,NWords,i1,i2,frnumber,wordsnumber;
int *wordcounter,wn,nword[20],j11,j2,j9,*filecounter,spaceforfiles=0;
int spaceforwords;
char ifilename[150],filename[150],FoNW[150];
FILE *f,*f1,*f2,*f3,*f4;
char
fout2[91],string[10],*fout,**qout,yorn,mode[10],*lslash,*dot,fout3[150],fullpath
[150],fullpath2[150],copy[20],**arrayofwords,**arrayoffiles,*semicolon,*copy1;
bool sq=false,*wordinside,serror,pmfon=false,**foundfiles;
double rwn;
WIN32_FIND_DATAA data2;
HANDLE hFind;
void fmain();
void setq();
void pm_file();
void packetmode();
void match();
void lenght_split();
void lenght_match();
void table_match();
int main(int argc, char* argv[])
{
    serror=false;
    if (argc==1)
    {
        printf("error");
        return 2;
    }
    else
```



```

        if (strcmp(argv[i], "-lr") == 0)
strcpy(lenghtResult, argv[i+1]);
    };
};

};

if(strncmp(mode, "m", 1) == 0)
{
    if (strcmp(argv[i], "-ifp") == 0)
strcpy(ifilepath, argv[i+1]);
    if (strcmp(argv[i], "-fp") == 0)
strcpy(filepath, argv[i+1]);
    if (strcmp(argv[i], "-pom") == 0)
strcpy(PathOfMatch, argv[i+1]);
    if (strncmp(mode, "mt", 2) == 0)
{
        if (strcmp(argv[i], "-t") == 0)
strcpy(pathoftables, argv[i+1]);
        if (strncmp(mode, "mtl", 3) == 0)
{
            if (strcmp(argv[i], "-lr") == 0)
strcpy(lenghtResult, argv[i+1]);
        };
    };
    if (strncmp(mode, "ml", 2) == 0)
{
        if (strcmp(argv[i], "-lr") == 0)
strcpy(lenghtResult, argv[i+1]);
    };
};

};

if (strcmp(mode, "of") == 0)
{
    fmain();
};

if(strncmp(mode, "pm", 2) == 0)
{
    packetmode();
    if(strncmp(mode, "pmm", 3) == 0)
{
        strcpy(ifilepath, ofilepath);
        strcat(ifilepath, "*");
        match();
}
}

```

```

        if(strncmp(mode,"pmmt",4)==0)
        {
            table_match();
            if(strncmp(mode,"pmmtl",5)==0)
                lenght_match();
        };
        if(strncmp(mode,"pmml",4)==0) lenght_match();
    };
}

if(strncmp(mode,"m",1)==0)
{
    match();
    if(strncmp(mode,"mt",2)==0)
    {
        table_match();
        if(strncmp(mode,"mtl",3)==0)
            lenght_match();
    };
    if(strncmp(mode,"ml",2)==0) lenght_match();
};
if (serror)
    return 1;
return 0;
}
void fmain()
{
    rwn=pow(4.0,org);
    if (rwn<maxwordsnumber)
    {
        wordsnumber=rwn;
    }
    else wordsnumber = maxwordsnumber;
    qout = new char*[wordsnumber];
    for (i=0; i<wordsnumber; i++) qout[i]=new char[org+1];
    wordinside = new bool[wordsnumber];
    f = fopen(ifilename, "r");
    if (!f)
    {
        printf("can't open reading file!");
        serror=true;
        goto end_fmain;
    };
    strcpy(fullpath, filepath);
}

```

```

strcat(fullpath, "dna.txt");
f1 = fopen(fullpath, "w");
if (!f1)
{
    printf("can't open file to write!");
    serror=true;
    goto end_fmain;
};

if(!pmfon)
{
    f2 = fopen(ofilename, "w");
    if (!f2)
    {
        printf("can't open file of output!");
        serror=true;
        goto end_fmain;
    };
    fclose(f2);
};

while (!feof(f))
{
    fgets(fout2, 91, f);
    if (strncmp(fout2, "SQ", 2) == 0)
    {
        sscanf(fout2,"%*s %*s %s",copy);
        frnumber = atoi(copy);
        sq = true;
        continue;
    };
    if (sq && (strlen(fout2)>5))
    {
        for (i=0;i<6;i++)
        {
            strncpy(string, fout2 + 5 + i * 11, 10);
            fprintf(f1, "%10.10s", string);
        };
    };
    fclose(f);
    fclose(f1);
    if (frnumber>maxfrnumber) frnumber=maxfrnumber;
    fout=new char[frnumber+1];
    strcpy(fullpath, filepath);
}

```

```

strcat(fullpath, "dna.txt");
f=fopen(fullpath, "r");
fgets(fout, frnumber+1, f);
strcpy(fullpath, filepath);
j = 1;
sprintf(fout2, "NF%03d.txt", j);
strcat(fullpath, fout2);
f1 = fopen(fullpath, "w");
fprintf(f1, "%s", fout);
if ((!feof(f)) && (fgetc(f) != ' '))
{
    do
    {
        fclose(f1);
        fclose(f);
        j++;
        strcpy(fullpath, filepath);
        strcat(fullpath, "dna.txt");
        f = fopen(fullpath, "r");
        strcpy(fullpath, filepath);
        sprintf(fout2, "NF%03d.txt", j);
        strcat(fullpath, fout2);
        f1 = fopen(fullpath, "w");
        for (i=0;i<j-1;i++) fgets(fout,frnumber-froverlap+1,f);
        fgets(fout,frnumber+1,f);
        fprintf(f1,"%s",fout);
    }while (!feof(f));
}else j++;
fclose(f1);
fclose(f);
NFile = j;
while (q <= org)
{
    setq();
    q++;
};
q--;
strcpy(fullpath, filepath);
strcat(fullpath, "qnext.txt");
f1 = fopen(fullpath, "r");
j = 1;
while (!feof(f1))
{

```

```

strcpy(fullpath, filepath);
sprintf(fout2, "NW%03d.txt", j);
strcat(fullpath, fout2);
f3 = fopen(fullpath, "w");
strcpy(fullpath, filepath);
sprintf(fout2, "W%03d.txt", j);
strcat(fullpath, fout2);
f = fopen(fullpath, "w");
for (i = 0; i<wordsnumber; i++)
{
    fscanf(f1, "%s ", copy);
    fprintf(f3, "0 ");
    fprintf(f, "%s ", copy);
    if (feof(f1))break;
}
fclose(f);
fclose(f3);
j++;
};

fclose(f1);
NWords=j;
if(!pmfon)
{
    strcpy(fullpath, filepath);
    strcat(fullpath, "nmw.txt");
    f2=fopen(fullpath, "w");
};
for (i = 1; i<NFfile; i++)
{
    fwc = 0;
    strcpy(fullpath, filepath);
    sprintf(fout2, "NF%03d.txt", i);
    strcat(fullpath, fout2);
    f = fopen(fullpath, "r");
    fscanf(f, "%s", fout);
    fclose(f);
    for (j = 1; j<NWords; j++)
    {
        strcpy(fullpath, filepath);
        sprintf(fout2, "NW%03d.txt", j);
        strcat(fullpath, fout2);
        f3 = fopen(fullpath, "r");
        strcpy(fullpath, filepath);

```

```

        sprintf(fout2, "W%03d.txt", j);
        strcat(fullpath, fout2);
        f1 = fopen(fullpath, "r");
        for (k = 0; k<wordsnumber; k++)
        {
            fscanf(f1, "%s ", qout[k]);
            fscanf(f3, "%s ", copy);
            i1 = atoi(copy);
            if (i1 == 0)
            {
                wordinside[k] = false;
            }
            else wordinside[k] = true;
            if (feof(f1))break;
        };
        i2 = k;
        fclose(f1);
        fclose(f3);
        strcpy(fullpath, filepath);
        sprintf(fout2, "NW%03d.txt", j);
        strcat(fullpath, fout2);
        f3 = fopen(fullpath, "w");
        for (k = 0; k<=i2; k++)
        {
            if (!wordinside[k])
            {
                if (strstr(fout, qout[k]) == NULL)
                {
                    if (pmfon)
                    {
                        fclose(f3);
                        strcpy(fullpath,filepath);
                        strcat(fullpath, "fonw.txt");
                        f4=fopen(fullpath,"a");
                        fprintf(f4,"%s %d\n",
data2.cFileName,orq);
                        fclose(f4);
                        pmfon=false;
                        goto end_fmain_m;
                    };
                    fprintf(f3, "0 ");
                    fwC++;
                }
            }
        }
    }
}

```

```

        else fprintf(f3, "1 ");
    }
    else fprintf(f3, "1 ");
    if ((!pmfon)&&((k+1)%5000==0)) printf("number of words=%d, number of missing words= %d\n", k+1, fwc);
}
fclose(f3);
};

if(!pmfon) fprintf(f2, "%d %d\n", i, fwc);
};

if(!pmfon)
{
    fclose(f2);
    f2 = fopen(ofilename, "w");
    if (!f2) { printf("can't open file!"); serror=true; goto end_fmain;};
    fwc = 0;
    for (j=1;j<NWords;j++)
    {
        strcpy(fullpath,filepath);
        sprintf(fout2,"W%03d.txt",j);
        strcat(fullpath,fout2);
        f1=fopen(fullpath,"r");
        for (k=0;k<wordsnumber;k++)
            fscanf(f1, "%s ", qout[k]);
        fclose(f1);
        strcpy(fullpath,filepath);
        sprintf(fout2,"NW%03d.txt",j);
        strcat(fullpath,fout2);
        f3=fopen(fullpath,"r");
        for (k=0;k<wordsnumber;k++)
        {
            fscanf(f3,"%s ",copy);
            i1=atoi(copy);
            if (i1==0)
            {
                fwc++;
                fprintf(f2,"%s ",qout[k]);
            };
        };
        fclose(f3);
    };
    fclose(f2);
}

```

```

};

end_fmain_m:
    delete [] fout;
    delete [] wordinside;
    for (k=0;k<wordsnumber;k++)
        delete [] qout[k];
    delete [] qout;
end_fmain:;
}

void setq()
{
    FILE *f, *f1;
    char finput[20],foutput[20],v;
    if (q == 1)
    {
        strcpy(fullpath, filepath);
        strcat(fullpath, "qnext.txt");
        f = fopen(fullpath, "w");
        fputs("a c g t ", f);
        fclose(f);
    }
    else
    {
        strcpy(fullpath, filepath);
        strcat(fullpath, "qprev.txt");
        f = fopen(fullpath, "r");
        strcpy(fullpath, filepath);
        strcat(fullpath, "qnext.txt");
        f1 = fopen(fullpath, "w");
        while (!feof(f))
        {
            fscanf(f, "%s ", foutput);
            strcpy(finput, foutput);
            strcat(finput, "a ");
            fputs(finput, f1);
            strcpy(finput, foutput);
            strcat(finput, "c ");
            fputs(finput, f1);
            strcpy(finput, foutput);
            strcat(finput, "g ");
            fputs(finput, f1);
            strcpy(finput, foutput);
            strcat(finput, "t ");
        }
    }
}

```

```

        fputs(finput, f1);
    };
    fclose(f);
    fclose(f1);
};

strcpy(fullpath, filepath);
strcat(fullpath, "qprev.txt");
f = fopen(fullpath, "w");
strcpy(fullpath, filepath);
strcat(fullpath, "qnnext.txt");
f1 = fopen(fullpath, "r");
while (!feof(f1))
{
    v = fgetc(f1);
    if (v>0) fputc(v, f);
};
fclose(f);
fclose(f1);
}

void packetmode()
{
    pm_file();
    strcpy(FoNW,filepath);
    strcat(FoNW, "fonw.txt");
    hFind=FindFirstFileA(ifilepath,&data2);
    if (hFind != INVALID_HANDLE_VALUE)
    {
        if( data2.dwFileAttributes != FILE_ATTRIBUTE_DIRECTORY )
        {
            if (strcmp(ofilepath,"\\0")==0)
            {
                printf("Can't open output directory!");
                serror=true;
                goto end_pm;
            };
            f4=fopen(FoNW, "r");
            if (!f4)
            {
                printf("Can't open file of numbers of symbols of
possibly missed words!");
                serror=true;
                goto end_pm;
            };

```

```

        strncpy(ifilename, ifilepath, strlen(ifilepath)-1);
        ifilename[strlen(ifilepath)-1]='\0';
        strcat(ifilename,data2.cFileName);
        lslash=strrchr(ifilename,'\\');
        lslash++;
        dot=strchr(lslash,'.');
        strcpy(ofilename,ofilepath);
        strncat(ofilename,lslash,dot-lslash);
        strcat(ofilename,".avs");
        while (!feof(f4))
        {
            fgets(fout3, 150, f4);
            if (strncmp(lslash, fout3, strlen(lslash)) == 0)
            {
                sq=true;sscanf(fout3,"%*s
%s",copy);orq=atoi(copy);break;
            };
        };
        fclose(f4);
        if (!sq)
        {
            printf("Can't find number of symbols of possibly missed
words in file. If you DOESN'T want to continue write n ");
            scanf("%c",yorn);
            if (yorn=='n') {goto end_pm;}
            else goto continue_pm;
        };
        sq=false;q=1;fwc=0;
        fmain();
    }
    else printf("directory\n");
continue_pm:
    do
    {
        if( data2.dwFileAttributes != FILE_ATTRIBUTE_DIRECTORY )
        {
            if (strcmp(ofilepath,"\\0")==0)
            {
                printf("Can't open output directory!");
                serror=true;
                goto end_pm;
            };
            f4=fopen(FoNW, "r");

```

```

        if (!f4)
        {
            printf("Can't open file of numbers of symbols of
possibly missed words!");
            serror=true;
            goto end_pm;
        };
        strncpy(ifilename,filepath,strlen(filepath)-1);
        ifilename[strlen(filepath)-1]='\0';
        strcat(ifilename,data2.cFileName);
        lslash=strrchr(ifilename,'\\');
        lslash++;
        dot=strchr(lslash,'.');
        strcpy(ofilename,filepath);
        strncat(ofilename,lslash,dot-lslash);
        strncat(ofilename,".avs");
        while (!feof(f4))
        {
            fgets(fout3, 150, f4);
            if (strcmp(lslash, fout3, strlen(lslash)) == 0)
            {
                sq = true;
                sscanf(fout3,"%*s %s",copy);
                orq = atoi(copy);
                break;
            };
        };
        fclose(f4);
        if (!sq)
        {
            printf("Can't find number of symbols of possibly
missed words in file. If you DOESN'T want to continue write n ");
            scanf("%c",yorn);
            if (yorn=='n') {goto end_pm;}
            else continue;
        };
        sq=false;fwc=0;q=1;
        printf("working with file %s, number of symbols
%d\n",ifilename,orq);
        fmain();
    }
    else printf("directory\n");
}while(FindNextFileA(hFind,&data2));

```

```

        }else printf("Can't open input directory!");
end_pm:;
}
void pm_file()
{
    hFind=FindFirstFileA(ifilepath,&data2);
    if (hFind != INVALID_HANDLE_VALUE)
    {
        strcpy(fullpath,filepath);
        strcat(fullpath, "fonw.txt");
        f4=fopen(fullpath,"w");
        fclose(f4);
        pmfon=true;
        if( data2.dwFileAttributes != FILE_ATTRIBUTE_DIRECTORY )
        {
            strncpy(ifilename,filepath,strlen(filepath)-1);
            ifilename[strlen(filepath)-1]='\0';
            strcat(ifilename,data2.cFileName);
            for (orq=1;orq<15;orq++)
            {
                sq=false;q=1;fwc=0;
                fmain();
                if (!pmfon)
                {
                    pmfon=true;break;
                };
            };
        }
        else printf("directory\n");
        do
        {
            if( data2.dwFileAttributes != FILE_ATTRIBUTE_DIRECTORY )
            {
                strncpy(ifilename,filepath,strlen(filepath)-1);
                ifilename[strlen(filepath)-1]='\0';
                strcat(ifilename,data2.cFileName);
                for (orq=1;orq<15;orq++)
                {
                    sq=false;q=1;fwc=0;
                    fmain();
                    if (!pmfon)
                    {
                        pmfon=true;break;
                    };
                };
            }
        }
    }
}

```

```

        } ;
    } ;
    printf("worked with file %s, calculated number of
symbols %d\n",ifilename,org);
}
else printf("directory\n");
}while(FindNextFileA(hFind,&data2));
pmfon=false;
}else printf("Can't open input directory!");
}
void match()
{
    strcpy(fullpath,filepath);
    strcat(fullpath, "fonw.txt");
    f2=fopen(fullpath,"r");
    if (!f2)
    {
        printf("Can't open file of numbers of symbols of possibly missed
words! ");
        serror=true;
        goto end_match;
    };
    fclose(f2);
    strcpy(fullpath,filepath);
    strcat(fullpath, "res_filenames.txt");
    f=fopen(fullpath,"w");
    fclose(f);
    filecounter=new int [20];
    for (i=0;i<20;i++)
        filecounter[i]=0;
    lenght_split();
    for (i=0; i<20; i++)
        if (spaceforfiles<((filecounter[i]*10)+1))
            spaceforfiles=(filecounter[i]*10)+1;
    delete [] filecounter;
    for (org=1;org<20;org++)
    {
        printf("\nq=%d\n",q);
        sprintf(copy,"%d",org);
        strcpy(fullpath,filepath);
        strcat(fullpath, "fonw");
        strcat(fullpath, copy);
        strcat(fullpath, ".txt");

```

```

f3=fopen(fullpath,"r");
if (!f3) continue;
fclose(f3);
strncpy(fullpath,filepath,strlen(filepath)-2);
fullpath[strlen(filepath)-2]='\0';
lslash=strrchr(fullpath,'\\');
lslash++;
dot=strchr(fullpath,'\\');
strcpy(fullpath2,PathOfMatch);
strncat(fullpath2,lslash,dot-lslash);
strcat(fullpath2, copy);
strcat(fullpath2, ".txt");
f=fopen(fullpath2,"w");
if (!f)
{
    printf("can't open file to write!");
    serror=true;
    goto end_match;
};
fclose(f);
strcpy(fullpath,filepath);
strcat(fullpath, "res_filenames.txt");
f=fopen(fullpath,"a");
fprintf(f,"%s %d\n",fullpath2,org);
fclose(f);
rwn=pow(4.0,org);
if (rwn<maxwordsnumber)
{wordsnumber=rwn;}
else wordsnumber = maxwordsnumber;
qout=new char*[wordsnumber];
wordcounter=new int[wordsnumber];
arrayoffiles=new char*[wordsnumber];
for (i=0; i<wordsnumber; i++)
{
    qout[i]=new char[org+1];
    arrayoffiles[i]=new char[spaceforfiles];
    strcpy(arrayoffiles[i]," ");
    wordcounter[i]=0;
};
q=1;
while (q <= org)
{
    setq();

```

```

        q++;
    };
    q--;
    strcpy(fullpath, filepath);
    strcat(fullpath, "qnext.txt");
    f1=fopen(fullpath, "r");
    j=1;
    while (!feof(f1))
    {
        strcpy(fullpath, filepath);
        sprintf(fout2, "W%03d.txt", j);
        strcat(fullpath, fout2);
        f = fopen(fullpath, "w");
        for (i = 0; i<wordsnumber; i++)
        {
            fscanf(f1, "%s ", copy);
            fprintf(f, "%s ", copy);
            if (feof(f1))break;
        };
        fclose(f);
        j++;
    };
    fclose(f1);
    NWords = j;
    copy[0]='\0';
    hFind=FindFirstFileA(ifilepath,&data2);
    if (hFind != INVALID_HANDLE_VALUE)
    {
        if( data2.dwFileAttributes != FILE_ATTRIBUTE_DIRECTORY )
        {
            strncpy(ifilename,ifilepath,strlen(ifilepath)-1);
            ifilename[strlen(ifilepath)-1]='\0';
            strcat(ifilename,data2.cFileName);
            lslash=strrchr(ifilename,'\\');
            lslash++;
            dot=strchr(lslash,'.');
            sprintf(copy,"%d",dot);
            strcpy(fullpath,filepath);
            strcat(fullpath, "fonw");
            strcat(fullpath, copy);
            strcat(fullpath, ".txt");
            f3=fopen(fullpath,"r");
            while (!feof(f3))

```

```

{
    fgets(fout3, 150, f3);
    sq=true;
    if (strncmp(lslash,fout3,strlen(lslash)-3)==0)
    {
        sq=false;
        break;
    };
};

fclose(f3);
copy[0]='\0';
if(sq) goto continue_match;
k=0;sq=false;
printf("working with file %s\n",ifilename);
f=fopen(ifilename,"r");
while (!feof(f))
{
    fscanf(f, "%s ",copy);
    k++;
    if (strcmp(copy, "\0") == 0) sq=true;
};

fclose(f);
if(sq) goto continue_match;
f=fopen(ifilename,"r");
arrayofwords=new char*[k];
for (i=0; i<k; i++)
{
    fscanf(f, "%s ",copy);
    arrayofwords[i]=new char[org+1];
    strcpy(arrayofwords[i],copy);
};

fclose(f);
for (j = 1; j<NWords; j++)
{
    strcpy(fullpath, filepath);
    sprintf(fout2, "W%03d.txt", j);
    strcat(fullpath, fout2);
    f1 = fopen(fullpath, "r");
    for (i=0; i<wordsnumber; i++)
    {
        fscanf(f1, "%s ", qout[i]);
    };
    fclose(f1);
}

```

```

        for (i1=0;i1<k;i1++)
        {
            for (i=0; i<wordsnumber; i++)
                if
(strncmp(qout[i],arrayofwords[i1])==0)
{
    strncat(arrayoffiles[i],lslash,dot-lslash);
    strcat(arrayoffiles[i],";");
    wordcounter[i]++;
    break;
};

};

for (i=0;i<k;i++)delete [] arrayofwords[i];
}

else printf("directory\n");

continue_match:
do
{
    if( data2.dwFileAttributes!= FILE_ATTRIBUTE_DIRECTORY)
    {
        strncpy(ifilename,filepath,strlen(filepath)-1);
        ifilename[strlen(filepath)-1]='\0';
        strcat(ifilename,data2.cFileName);
        lslash=strrchr(ifilename,'\\');
        lslash++;
        dot=strchr(lslash,'.');
        sprintf(copy,"%d",orq);
        strcpy(fullpath,filepath);
        strcat(fullpath, "fonw");
        strcat(fullpath, copy);
        strcat(fullpath, ".txt");
        f3=fopen(fullpath,"r");
        while (!feof(f3))
        {
            fgets(fout3, 150, f3);
            sq=true;
            if (strncmp(lslash,fout3,strlen(lslash)-3)==0)
            {
                sq=false;
                break;
            }
        }
    }
}

```

```

    } ;
}

fclose(f3) ;
copy[0]='\0' ;
if(sq) continue;
k=0;sq=false;
printf("working with file %s\n",ifilename);
f=fopen(ifilename,"r");
while (!feof(f))
{
    fscanf(f, "%s ",copy);
    k++;
    if (strcmp(copy, "\0") == 0)
        sq=true;
}
fclose(f);
if(sq) continue;
f=fopen(ifilename,"r");
arrayofwords=new char*[k];
for (i=0; i<k; i++)
{
    fscanf(f, "%s ",copy);
    arrayofwords[i]=new char[org+1];
    strcpy(arrayofwords[i],copy);
}
fclose(f);
for (j = 1; j<NWords; j++)
{
    strcpy(fullpath, filepath);
    sprintf(fout2, "W%03d.txt", j);
    strcat(fullpath, fout2);
    f1 = fopen(fullpath, "r");
    for (i=0; i<wordsnumber; i++)
    {
        fscanf(f1, "%s ", qout[i]);
    };
    fclose(f1);
    for (il=0;il<k;il++)
    {
        for (i=0; i<wordsnumber; i++)
            if
(strcmp(qout[i],arrayofwords[il]) == 0)
{

```

```

strncat(arrayoffiles[i], lslash, dot-lslash);

strcat(arrayoffiles[i], ";");
wordcounter[i]++;
break;
};

};

for (i=0;i<k;i++) delete [] arrayofwords[i];
delete [] arrayofwords;
}

else printf("directory\n");

}while(FindNextFileA(hFind, &data2));

f=fopen(fullpath2,"w");
for (i=0; i<wordsnumber; i++)
if (wordcounter[i]!=0)
fprintf(f,"%s
%d%s\n",qout[i],wordcounter[i],arrayoffiles[i]);
fclose(f);
}else printf("Can't open input directory!");
delete [] wordcounter;
for (k=0;k<wordsnumber;k++)
{
delete [] qout[k];
delete [] arrayoffiles[k];
};
delete [] qout;
delete [] arrayoffiles;
};

end_match:;
printf("end of match");
}

void lenght_split()
{
strcpy(fullpath,filepath);
strcat(fullpath, "fonw.txt");
f2=fopen(fullpath,"r");
while (!feof(f2))
{
fgets(fout3, 150, f2);
sscanf(fout3,"%*s %s",copy);
strcpy(fullpath,filepath);
}
}

```

```

        strcat(fullpath, "fonw");
        strcat(fullpath, copy);
        strcat(fullpath, ".txt");
        f3=fopen(fullpath,"w");
        fclose(f3);

    };

    fclose(f2);
    strcpy(fullpath,filepath);
    strcat(fullpath, "fonw.txt");
    f2=fopen(fullpath,"r");
    while (!feof(f2))
    {
        fgets(fout3, 150, f2);
        if (strcmp(fout3,"\\0")==0) break;
        sscanf(fout3,"%*s %s",copy);
        i=atoi(copy);
        filecounter[i-1]++;
        strcpy(fullpath,filepath);
        strcat(fullpath, "fonw");
        strcat(fullpath, copy);
        strcat(fullpath, ".txt");
        f3=fopen(fullpath,"a");
        fputs(fout3,f3);
        fclose(f3);
    };
    fclose(f2);
}

void lenght_match()
{
    printf("starting lenght_match...");
    arrayofwords=new char*[1];
    arrayofwords[0]=new char[1000];
    strcpy(arrayofwords[0],"\\0");
    for (i=0;i<20;i++) nword[i]=0;
    strcpy(fullpath,filepath);
    strcat(fullpath, "res_filenames.txt");
    f=fopen(fullpath,"r");
    while(!feof(f))
    {
        fscanf(f,"%s %s\n",fullpath2,copy);
        orq=atoi(copy);
        f1=fopen(fullpath2,"r");
        while(!feof(f1))

```

```

{
    fgets(arrayofwords[0],1000,f1);
    if (strcmp(arrayofwords[0],"\\0")!=0) nword[orq-1]++;
    strcpy(arrayofwords[0],"\\0");
}
fclose(f1);
};

fclose(f);
delete [] arrayofwords[0];
NWords=0;
for (i=0;i<20;i++) NWords+=nword[i];
arrayofwords=new char*[NWords+1];
for (i=0; i<NWords+1; i++)
{
    arrayofwords[i]=new char[1000];
    strcpy(arrayofwords[i],"\\0");
};
i=0;
f=fopen(fullpath,"r");
while(!feof(f))
{
    fscanf(f,"%s %s\n",fullpath2,copy);
    orq=atoi(copy);
    f1=fopen(fullpath2,"r");
    while(!feof(f1))
    {
        fgets(arrayofwords[i],1000,f1);
        i++;
    };
    fclose(f1);
    if (i<NWords)
    {
        if (strcmp(arrayofwords[i],"\\0")==0)i--;
    }
    else i--;
};
fclose(f);
f=fopen(lenghtResult,"w");
for (orq=20;orq>0;orq--)
{
    if ((nword[orq-1]!=0)&&(nword[orq-2]!=0))
    {
        i=0;
        for (j=0;j<orq-2;j++) i+=nword[j];

```

```

        i1=i+nword[org-2];
        i2=i1+nword[org-1];
        for (j=i;j<i1;j++)
        {
            sscanf(arrayofwords[j],"%s %*s %*s",copy);
            for (k=i1;k<i2;k++)
                if (strstr(arrayofwords[k],copy)!=NULL)
                {

fprintf(f,"%s%s\n",arrayofwords[k],arrayofwords[j]);
    };
};

fclose(f);
printf("done\n");
}

void table_match()
{
    spaceforwords=spaceforfiles+26;
    copy1=new char[spaceforwords];
    printf("starting table_match...");
    arrayofwords=new char*[1];
    arrayofwords[0]=new char[spaceforwords];
    strcpy(arrayofwords[0],"\\0");
    for (i=0;i<20;i++) nword[i]=0;
    strcpy(fullpath,filepath);
    strcat(fullpath, "res_filenames.txt");
    f=fopen(fullpath,"r");
    while(!feof(f))
    {
        fscanf(f,"%s %s\n",fullpath2,copy);
        org=atoi(copy);
        f1=fopen(fullpath2,"r");
        while(!feof(f1))
        {
            fgets(arrayofwords[0],spaceforwords,f1);
            if (strcmp(arrayofwords[0],"\\0")!=0) nword[org-1]++;
            strcpy(arrayofwords[0],"\\0");
        };
        fclose(f1);
    };
    fclose(f);
    delete [] arrayofwords[0];
}

```

```

delete [] arrayofwords;
NWords=0;
for (i=0;i<20;i++) NWords+=nword[i];
arrayofwords=new char*[NWords+1];
for (i=0; i<NWords+1; i++)
{
    arrayofwords[i]=new char[spaceforwords];
    strcpy(arrayofwords[i],"\0");
};

i=0;
f=fopen(fullpath,"r");
while(!feof(f))
{
    fscanf(f,"%s %s\n",fullpath2,copy);
    orq=atoi(copy);
    f1=fopen(fullpath2,"r");
    while(!feof(f1))
    {
        fgets(arrayofwords[i],spaceforwords,f1);
        i++;
    };
    fclose(f1);
    if (i<NWords)
    {
        if (strcmp(arrayofwords[i],"\0")==0)i--;
    }
    else i--;
};
fclose(f);
for (orq=20;orq>0;orq--)
{
    if (nword[orq-1]!=0)
    {
        i=0;
        for (j=0;j<orq-1;j++) i+=nword[j];
        i1=i+nword[orq-1];
        arrayoffiles=new char*[i1-i];
        for (j=0;j<i1-i;j++) arrayoffiles[j]=new char[100];
        k=0;
        for (j=i;j<i1;j++)
        {
            sscanf(arrayofwords[j],"%*s %*s %s",copy1);
            semicolon=strchr(copy1,';');
            strncpy(arrayoffiles[k],copy1,semicolon-copy1);

```

```

arrayoffiles[k][semicolon-copy1]='\0';
for(i2=0;i2<k;i2++)
{
    if(strcmp(arrayoffiles[k],arrayoffiles[i2])==0)
    {
        k--;
        break;
    };
    k++;
    strcpy(copy1,semicolon+1);
    semicolon=strchr(copy1,';');
    while (semicolon!=NULL)
    {
        strncpy(arrayoffiles[k],copy1,semicolon-copy1);
        arrayoffiles[k][semicolon-copy1]='\0';
        for(i2=0;i2<k;i2++)
}

if(strcmp(arrayoffiles[k],arrayoffiles[i2])==0)
{
    k--;
    break;
};

k++;
semicolon=strchr(copy1,';');
if(semicolon==NULL)
{
    k--;
    break;
};
strcpy(copy1,semicolon+1);
};

};

foundfiles=new bool*[il-i];
for (j=0;j<il-i;j++)
{
    foundfiles[j]=new bool[k];
    for(j2=0;j2<k;j2++)
        foundfiles[j][j2]=false;
};

for (j=i;j<il;j++)
{
    sscanf(arrayofwords[j],"%*s %s %*s",copy);
    wn=atoi(copy);
    if (wn>1)

```

```

    {
        sscanf(arrayofwords[j], "%*s %*s %s", copy1);
        semicolon=strchr(copy1,';');
        strncpy(copy,copy1,semicolon-copy1);
        copy[semicolon-copy1]='\0';
        for(j2=0;j2<k;j2++)
            if(strcmp(copy,arrayoffiles[j2])==0)
            {
                foundfiles[j-i][j2]=true;
                strcpy(copy1,semicolon+1);
                semicolon=strchr(copy1,';');
                if (semicolon!=NULL)
                {
                    j2=-1;
                    strncpy(copy,copy1,semicolon-
copy1);
                    copy[semicolon-copy1]='\0';
                }
            };
        };
    };
    strcpy(fullpath,filepath,strlen(filepath)-2);
    fullpath[strlen(filepath)-2]='\0';
    lslash=strrchr(fullpath,'\\');
    lslash++;
    dot=strchr(fullpath,'\\');
    sprintf(copy,"%d",orq);
    strcpy(fullpath2,pathoftables);
    strncat(fullpath2,lslash,dot-lslash);
    strncat(fullpath2, copy);
    strncat(fullpath2, ".txt");
    f=fopen(fullpath2,"w");
    for(j=0;j<20;j++)
    {
        fputs(" ",f);
    };
    j11=0;
    for(j=0;j<k;j++)
    {
        fprintf(f,"%s ",arrayoffiles[j]);
        j11+=strlen(arrayoffiles[j])+1;
    };
    j11=j11/(2*k);
}

```

```

fputs("\n", f);
for (j=i;j<i1;j++)
{
    sscanf(arrayofwords[j],"%*s %s %*s",copy);
    wn=atoi(copy);
    if (wn>1)
    {
        sscanf(arrayofwords[j],"%s %*s %*s",copy);
        fprintf(f,"%s ",copy);
        j9=20-strlen(copy);
        for(i2=0;i2<j9;i2++) fputs(" ",f);
        for(j2=0;j2<k;j2++)
        {
            for(i2=0;i2<j11;i2++) fputs(" ",f);
            if(foundfiles[j-i][j2])
            {
                fputs("+",f);
            }
            else fputs("-",f);
            for(i2=0;i2<j11-1;i2++) fputs(" ",f);
        };
        fputs("\n",f);
    };
}
fclose(f);
for (j=0;j<i1-i;j++)
{
    delete [] arrayoffiles[j];
    delete [] foundfiles[j];
};
delete [] arrayoffiles;
delete [] foundfiles;
};

for (i=0; i<NWords; i++) delete [] arrayofwords[i];
delete [] arrayofwords;
delete [] copy1;
printf("done\n");
}

```