

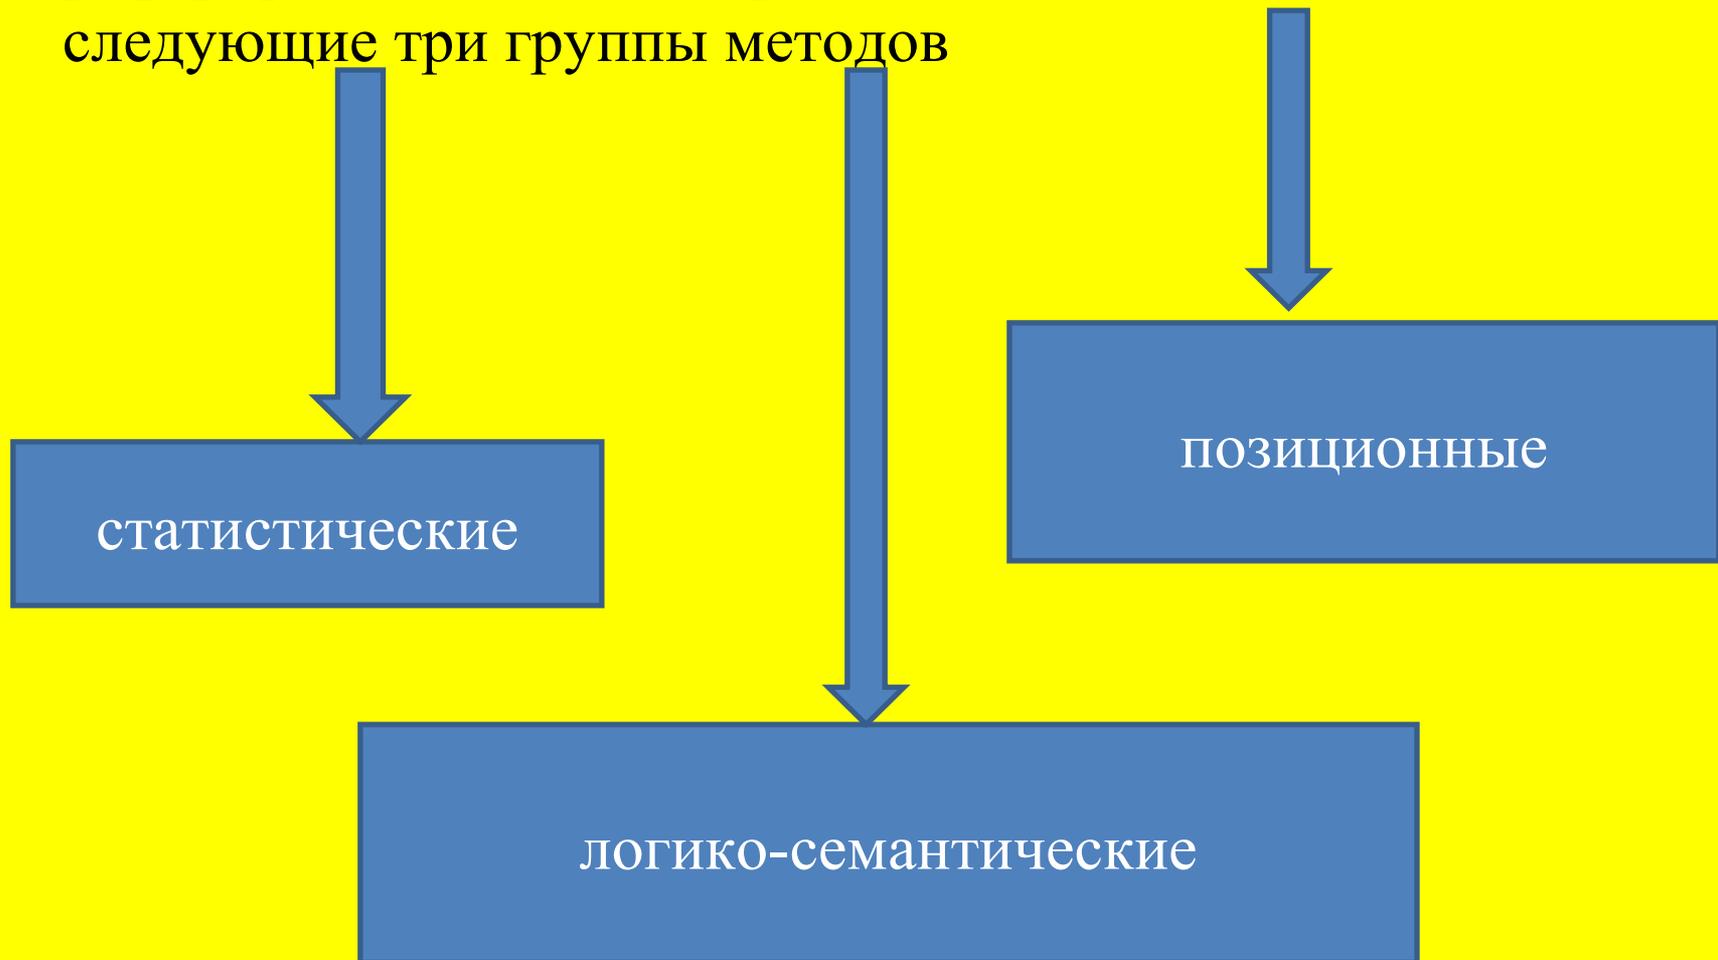
Говоря о двух последних «умениях» компьютера, необходимо помнить, что почти во всех существующих системах автоматического реферирования в качестве **основных смысловых единиц реферата** выступают ключевые предложения или ключевые словосочетания и слова исходного текста.

Первые в их последовательной совокупности (в том порядке, в котором они идут в исходном тексте) образуют текст (квазитекст) реферата.

Второй тип смысловых единиц (ключевые словосочетания и слова) используется компьютером для построения так называемых *табличных рефератов*.

При составлении с помощью компьютера аннотации также используются как ключевые предложения (в том виде, что и при составлении реферата), так и ключевые слова и словосочетания. Последние перечисляются вслед за реляторами вида: «В статье рассматриваются следующие вопросы:...», «Книга посвящена следующим проблемам: ...», «Статья раскрывает следующие понятия: ...» и т.д.

По способам выделения из исходных текстов ключевых словосочетаний и предложений (первые два «умения» компьютера) различают несколько методов автоматического реферирования и аннотирования текстов. Наиболее известны следующие три группы методов



Суть статистической группы методов заключается в том, что

ключевыми словами считаются такие знаменательные слова текста, которые с учетом всех синонимов встречаются в тексте наибольшее число раз

ключевым предложением считается предложение текста, которое

имеет несколько
ключевых слов

содержит ключевые слова на
небольшом расстоянии друг
от друга

Принадлежность слова, словосочетания или предложения к числу ключевых определяется **специальными статистическими коэффициентами.**

В *позиционных методах* автоматического реферирования и аннотирования ключевым предложением считается предложение, входящее в заголовок, подзаголовок, начало или конец какой-то части текста или всего текста.

Такие предложения, как правило, содержат информацию о целях, методах, выводах и результатах исследования, описанного в первичном документе.

Важность тех или иных предложений с указанной точки зрения определяется экспертами путем изучения семантической структуры первичных документов определенного типа.

Логико-семантические методы опираются на исследование структуры и семантики текстов.

Существует несколько вариантов этих методов, но цель их одна — выделить из конкретного текста предложения с **наибольшим функциональным весом**.

Величина эта зависит от многих факторов:

- наличия в исследуемом предложении специальных семантически значимых слов,
- связи этого предложения с другими предложениями текста,
- синтаксического типа самого предложения и т.д.

Формулируя задачу построения системы автоматического аннотирования и реферирования текста, необходимо четко указать

метод, который используется для выделения ключевых слов предложения

способ определения ключевых словосочетаний предложения

критерий выделения ключевых предложений текста

тип подготавливаемой аннотации: текстовая, в виде релятора с последующими ключевыми словами и словосочетаниями, или табличная

тип формируемого реферата: текстовый или табличный

Учитывая все сказанное, сформулируем задачу *автоматического реферирования и аннотирования текста* следующим образом

На устройстве внешней памяти (например, дискете или винчестере) находится английский научно-технический текст. Начало каждого абзаца в нем обозначено знаком*. Используя для выделения ключевых (опорных) слов текста один из вариантов статистического метода, а именно коэффициент важности слова

$$K_{\text{важ}} = \frac{F \cdot m}{N \cdot n}$$

В формуле для $K_{\text{важ}}$ буквы означают следующее: F — частота словоупотреблений в тексте; m — число абзацев текста, в которых встретилось слово; N — общее число словоупотреблений в тексте; n — общее число абзацев в тексте.

Это позволяет получить

аннотацию текста в виде релятора со следующими за ним ключевыми словосочетаниями текста. Ключевым сочетанием считается ключевое имя существительное со стоящим перед ним определением, выраженным именем прилагательным или причастием, не относящимся к числу общеупотребительных

словесный реферат текста в виде последовательной цепочки ключевых предложений. Ключевым предложением текста будем считать предложение, содержащее три и более разных ключевых слова.

Аннотацию и реферат вывести на экран дисплея

Исходным материалом для сформулированной выше задачи автоматического аннотирования и реферирования будет служить текст

•MICROPROCESSORS AND MINICOMPUTERS.

•THE FIRST COMPUTERS FILLED A LARGE ROOM WITH THEIR ELECTRONICS.

PHOTOGRAPHS OF EARLY COMPUTERS SHOW MEN AND WOMEN IN BUSINESS SUITS AND LABORATORY COATS STANDING IN THE MIDDLE OF A ROOM SURROUNDED BY A U-SHAPED MACHINE. IN REALITY, PEOPLE OPERATING AND DEVELOPING THE FIRST COMPUTERS DID NOT WEAR SUITS. AIR-CONDITIONING WAS POOR AT THAT TIME AND THE COMPUTER GOT SO HOT THAT THE COMPUTER OPERATORS DRESSED IN T-SHIRTS AND TENNIS SHOES.

•THE DEVELOPMENT OF THE TRANSISTOR IN 1948 MADE IT POSSIBLE TO BUILD ELECTRONIC DEVICES OF A VERY SMALL SIZE. AN INTEGRATED CIRCUIT (IC(CHIP) FOR SHORT) WAS SOON DEVELOPED. AN IC(CHIP) IS A LARGE NUMBER OF TRANSISTORS AND OTHER ELECTRONIC COMPONENTS WIRED TOGETHER. THEY FORM A SPECIAL CIRCUIT AND ARE MICROSCOPICALLY PLACED ON A SMALL PIECE OF SILICON (OR OTHER MATERIAL) WHICH SERVES AS SEMICONDUCTOR.

•INTEGRATED CIRCUITS, ALSO CALLED CHIPS, ARE NOW MANUFACTURED SEPARATELY FROM COMPUTERS. THEY PROVIDE BUILDING BLOCKS TO BUILD A COMPUTER. THE MOST IMPORTANT OF THESE COMPUTER COMPONENTS IS THE CENTRAL PROCESSING UNIT (CPU FOR SHORT) OR MICROPROCESSOR. IT IS THE PART OF THE COMPUTER THAT OBEYS THE INSTRUCTIONS OF A PROGRAM. A MICROPROCESSOR IS A SMALL UNIT CONTAINED ON THE SEMICONDUCTOR CHIP. MICROPROCESSORS ARE USED IN MINICOMPUTERS AND EACH OF THESE INTEGRATED CIRCUITS IS CAPABLE OF PROCESSING 8-BIT OR 16-BIT DATA...

Принципиальный алгоритм решения задачи

Решаемая задача является сложной и состоит из нескольких простых подзадач

В *блоке А* в память компьютера вводится находящийся на устройстве внешней памяти файл с английским научно-техническим текстом.

Далее в *блоке В* формируется массив словоформ одного абзаца текста, словоформы сортируются по алфавиту, подсчитывается частота употребления каждой словоформы в абзаце и в специальной области компьютерной памяти создается алфавитно-частотный словарь одного абзаца. Подобные действия выполняются со всеми абзацами текста.

В результате выполнения *блоков А и В* алгоритма в специальных областях памяти компьютера будут расположены алфавитно-частотные словари словоформ всех семи абзацев текста.

Блок С объединяет алфавитно-частотные словари абзацев в единый распределительный алфавитно-частотный словарь текста. При этом каждой словоформе приписываются общая частота ее употребления во всем тексте (F), число абзацев (m) и конкретные номера абзацев (0, 1, 2, 3, 4, 5, 6-й), в которых встретилась эта словоформа.

Принципиальный алгоритм задачи автоматического реферирования и аннотирования текста

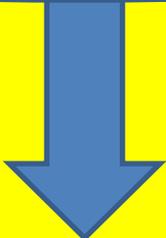
Ввод в память компьютера исходного текста



Создание алфавитно-частотных словарей абзацев текста



Создание распределительного алфавитно-частотного словаря текста



**Создание словаря потенциальных
опорных словоформ текста**

```
graph TD; A[Создание словаря потенциальных опорных словоформ текста] --> B[Создание словаря главных и второстепенных опорных словоформ текста]; B --> C[Выделение из текста ключевых словосочетаний для аннотации]; C --> D[ ];
```

**Создание словаря главных и
второстепенных опорных словоформ
текста**

**Выделение из текста ключевых
словосочетаний для аннотации**

**Выделение из текста ключевых
предложений для реферата**

```
graph TD; A[Выделение из текста ключевых предложений для реферата] --> B[Печать аннотации к тексту на экране дисплея]; B --> C[Печать реферата текста на экране дисплея];
```

**Печать аннотации к тексту на экране
дисплея**

**Печать реферата текста на экране
дисплея**

Распределительный алфавитно-частотный словарь словоформ текста (фрагменты)

| № п/п | Словоформа | Абсолютная частота употребления, F | Общее число абзацев в тексте, m | Номера абзацев, в которых встретилась словоформа |
|--------------|-----------------------|--------------------------------------|-----------------------------------|--|
| И | A | 25 | 6 | 123456 |
| 1 | AIR-CONDITIONG | 1 | 1 | 1 |
| 2 | ALSO | 1 | 1 | 3 |
| 3 | AN | 2 | 1 | 2 |
| 4 | AND | 17 | 7 | 0123456 |
| | | | | |
| 12 | BUILD | 2 | 2 | 23 |
| | | | | |
| 18 | CALLED | 3 | 3 | 356 |
| | | | | |
| | | | | |

Прежде чем сформулировать решаемую в *блоке D* подзадачу, следует ввести ряд уточнений. Выше, говоря о ключевых словах текста, отмечается три особенности этих слов

это слова-термины

они должны встречаться в тексте несколько раз

должны учитываться все возможные синонимы этого термина в тексте

В исходном тексте могут встречаться пары синонимов. В настоящее время без специальных, очень сложных программ компьютер не может сам их обнаружить. Большую помощь при определении синонимичности слов могут оказать словари-тезаурусы. Поэтому при записи текста на диск эти синонимы указываются. Далее синонимичные словоформы объединяются в одно условное слово с суммированием

- частот их употребления,
- объединением номеров абзацев, в которых они использовались,
- и их общего числа.

Синонимичными для компьютера являются и грамматические формы одних и тех же слов. Найти и объединить эти словоформы компьютер может самостоятельно, без специального редактирования текста человеком. В результате получается единое условное слово. В число потенциальных опорных словоформ текста логично включать только те из словоформ, которые встретились в двух и более абзацах (т.е. $m > 2$).

Наконец, чтобы учесть первую особенность ключевых слов и оставить в числе потенциальных опорных словоформ текста только термины, необходимо из всех словоформ исключить служебные словоформы (предлоги, частицы, артикли, местоимения, наречия, вспомогательные глаголы, числительные и т.д.) и словоформы с общеупотребительным значением. Эти две группы словоформ называют иногда *отрицательными, запрещенными* или *стоп-словами*.

Компьютер последовательно анализирует все словоформы распределительного словаря, начинающиеся с одной и той же буквы.

На первом шаге такого анализа она выделяет у второй из двух сравниваемых словоформ одну последнюю букву и оставшуюся часть второй словоформы сравнивает с первой словоформой.

Если они совпадают, компьютер **суммирует частоты этих словоформ, устанавливает номера абзацев,** в которых встретились эти словоформы, и **определяет общее количество абзацев, в которых они использовались.**

Число выделенных таким образом номеров абзацев и составляет величину m для единого условного слова.

Запись двух и более словоформ в виде, когда F и m указываются лишь для одной формы, а для других словоформ эти величины равны нулю, называется **условным словом**. Номера абзацев в последних словоформах оставлены от результатов предыдущих действий.

Если после отделения у 2-й словоформы одной последней буквы совпадения словоформ не произошло, то у 2-й словоформы выделяются две последние буквы и проводится новое сравнение оставшейся части с 1-й словоформой. В случае их совпадения выполняются аналогичные описанным выше действия.

Объединение данных о синонимичных словоформах проводится с опорой на тот факт, что такие словоформы в тексте по нашему первоначальному условию заключены в скобки и располагаются друг за другом.

Найдя основную словоформу, компьютер объединяет ее частоту с частотой **синонима**, уточняет число и конкретные номера абзацев по такому же принципу, как это было показано для объединения грамматических форм одного и того же слова.

Исключаются из распределительного алфавитно-частотного словаря те словоформы, которые встретились лишь в одном абзаце.

Исключение из распределительного словаря любой словоформы служебного или общеупотребительного слова, грамматической формы, синонима, словоформ, встречающихся в одном абзаце, осуществляется в виде **«сжатия» распределительного словаря**, с тем чтобы в нем не осталось ненужных словоформ.

При этом компьютер опирается на заранее заданный список запрещенных слов.

Итогом работы *блока D* является словарь потенциальных опорных словоформ исходного текста.

Основным критерием для создания словаря главных и второстепенных опорных словоформ текста (блок E) является коэффициент важности слова

$$K_{\text{важ}} = \frac{F \cdot m}{N \cdot n}$$

Словарь потенциальных опорных словоформ исходного текста

| № п/п | Словоформа | Абсолютная частота употреб-ления, F | Общее число абзацев в тексте, m | Номера абзацев, в которых встре-тилась данная словоформа |
|-------|------------|--|---|--|
| 0 | BUILD | 2 | 2 | 23 |
| 1 | CHIP | 6 | 3 | 234 |
| 2 | CHIPS | 10 | 0 | 0 |
| 3 | IC | 0 | 0 | 0 |
| 4 | CIRCUIT | 5 | 3 | 234 |
| 5 | CIRCUITS | 0 | 0 | 0 |
| 6 | COMPONENTS | 3 | 3 | 234 |

Среди ключевых словоформ текста может быть установлена следующая иерархия.

Одни из них — главные опорные слова (ГОС) — являются особенно важными для текста. Они встречаются с наибольшей частотой в большом числе абзацев. Другие опорные слова встречаются с меньшей частотой и в меньшем числе абзацев. Их называют второстепенными опорными словами (ВОС). Существуют разные методы определения ГОС и ВОС. В качестве критерия их различия используются граничные значения $K1_{важ}$ и $K2_{важ}$. Граничные значения этих коэффициентов при таком подходе зависят от числа абзацев текста.

Для текста, содержащего 7 абзацев, эти коэффициенты могут быть вычислены, например, по следующим формулам

$$\frac{9}{N \cdot n} \leq K_{\text{важ}}^1 < 1;$$

$$\frac{(1/4n + 1)^2}{N \cdot n} \leq K_{\text{важ}}^2 < \frac{9}{N \cdot n},$$

где N – общее число словоупотреблений текста; n – общее число абзацев текста

Для исследуемого текста, имеющего $y = 7$ абзацев и $N=395$ словоупотреблений, неравенства преобразуются в следующие

$$\frac{9}{395 \cdot 7} \leq K_{\text{важ}}^1 < 1;$$

$$0,0032 \leq K_{\text{важ}}^1 < 1;$$

$$\frac{(1/4 \cdot 7 + 1)^2}{395 \cdot 7} \leq K_{\text{важ}}^2 < 0,0032;$$

$$0,0027 \leq K_{\text{важ}}^2 < 0,0032.$$

Если для каждой словоформы, вошедшей в словарь потенциальных опорных словоформ, вычислить по формуле коэффициент важности $K1_{важ}$ и сравнить его с граничными значениями $K^1_{важ}$ и $K^2_{важ}$ то

главными опорными словоформами текста будем считать те, коэффициент важности которых удовлетворяет неравенству

$$0,0032 \leq K_{важ} < 1;$$

второстепенными опорными словоформами текста будем считать те, коэффициент важности которых удовлетворяет неравенству

$$0,0027 \leq K_{важ} < 0,0032$$

если же $K_{важ}$ словоформы меньше 0,0027, то эта словоформа относится к числу прочих словоформ текста.

Результатом работы *блока* Е является словарь главных и второстепенных опорных словоформ, представленный в таблице 14. В ней коэффициенты $K_{важ}$ относятся ко всей группе синонимичных словоформ, образующих одно условное слово.

Словарь главных и второстепенных опорных словоформ текста

| № п/п | Тип опорной словоформы | Словоформа | Кваж |
|--------------|-------------------------------|-------------------|---------------|
| 0 | ГОС | CHIP | 0,0065 |
| 1 | ГОС | CHIPS | — |
| 2 | ГОС | 1С | — |
| 3 | ГОС | CIRCUIT | 0,0054 |
| 4 | ГОС | CIRCUITS | — |
| 5 | ГОС | COMPONENTS | 0,0033 |
| 6 | ГОС | COMPUTER | 0,0338 |

Так как аннотация – это кратчайшее изложение содержания исходного, то она должна опираться на наиболее важные в смысловом отношении текстовые единицы, **т.е. на *главные опорные словоформы***. Они включают несколько имен существительных, одно имя прилагательное, одно причастие и одно сокращение.

В крупных промышленных системах автоматического реферирования и аннотирования в компьютерной памяти находится большой автоматический словарь, в котором каждому слову приписаны различные лексико-грамматические (часть речи, род, число, падеж, время и т.д.), семантические и другие признаки. Поэтому, опираясь на такой словарь, компьютер достаточно легко определит, к какой части речи относится каждая опорная словоформа.

Отнесение определителей к классам имени прилагательного и причастия может быть осуществлено по **автоматическому словарю**.

А выделение среди имен прилагательных и причастий общеупотребительных словоформ может быть сделано лишь путем **сравнения** каждого определения со специальным списком общеупотребительных имен прилагательных и причастий, помещенным в память компьютера.

Подзадачу, которая должна быть решена в блоке F , можно сформулировать так:

«Читая последовательно все предложения текста, выделить в них ключевые словосочетания (в указанном выше понимании), расположить их по алфавиту и удалить из них одинаковые».

В самом начале работы по автоматическому реферированию и аннотированию текста в память компьютера вводится список предлогов, артиклей, наречий, союзов, числительных, вспомогательных глаголов, местоимений, а также общеупотребительных имен прилагательных и причастий. Обработываемый текст уже находится в компьютерной памяти {блок А).

Далее начинается последовательное чтение отдельных предложений. В каждом прочитанном предложении компьютер ищет опорную словоформу — имя существительное.

Если она **найдена**, то компьютер выделяет из предложения словоформу, стоящую перед опорной, и сравнивает ее с введенным ранее в память списком служебных и общеупотребительных словоформ.

Словоформу-определение, **не найденную в таком списке**, компьютер объединяет со стоящим за ней опорным именем существительным и передает полученное словосочетание в специальную область памяти для ключевых словосочетаний текста.

На следующем этапе работы компьютер сортирует этот список по алфавиту. И наконец, на последнем этапе компьютер исключает из рассортированного списка ключевых словосочетаний полностью повторяющиеся словосочетания.

Если в таком списке встречаются словосочетания, различающиеся лишь признаком числа имени существительного (*integrated circuit* и *integrated circuits*), то в списке остается словосочетание с именем существительным во множественном числе.

В общей формулировке задачи построения системы автоматического реферирования и аннотирования отмечалось, что реферат представляет собой последовательность ключевых предложений текста. Само же ключевое предложение было определено как такое предложение текста, в котором содержится три и более разных опорных слова.

Поэтому подзадачу *блока G* сформулируем следующим образом: «Читая последовательно все предложения текста, выделить и запомнить те из них, в которых содержится три и более разных главных или второстепенных опорных слова данного текста».

Результатом работы *блока G* является *реферат текста* — последовательность ключевых предложений, в каждом из которых обнаружено три и более опорных словоформ текста.

В процессе выполнения *блока H* на экран дисплея выводится аннотация текста в виде полученных в *блоке F* ключевых словосочетаний, перед которыми ставится фраза (релятор) «THIS TEXT IS ABOUT:» («В ЭТОМ ТЕКСТЕ ГОВОРИТСЯ:»).

THIS TEXT IS ABOUT: COMPUTER COMPONENTS,
ELECTRONIC COMPONENTS, ELECTRONIC COMPUTERS,
INTEGRATED CIRCUITS, MEMORY CHIPS, PERSONAL
COMPUTER, SEMI-CONDUCTOR CHIP, SPECIAL CIRCUIT.

Выполнение *блока I* позволяет напечатать на экране дисплея все ключевые предложения текста. Они представляют собой его реферат:

AN INTEGRATED CIRCUIT (IC FOR SHORT) WAS SOON DEVELOPED. AN IC IS A LARGE NUMBER OF TRANSISTORS AND OTHER ELECTRONIC COMPONENTS WIRED TOGETHER. IN-TEGRATED CIRCUITS, ALSO CALLED CHIPS, ARE NOW MANU-FACTURED SEPARATELY FROM COMPUTERS. THE MOST IM-PORTANT OF THESE COMPUTER COMPONENTS IS THE CENTRAL PROCESSING UNIT (CPU FOR SHORT) OR MICROPROCESSOR. MICROPROCESSORS ARE USED IN MINICOMPUTERS AND EACH OF THESE INTEGRATED CIRCUIT IS CAPABLE OF PROCESSING 8-BIT OR 16-BIT DATA. SOME OTHER COMPONENTS OF A COMPUTER ARE COMPUTER MEMORY CHIPS, VOICE SYNTHE-SIZERS THAT PRODUCE SOUNDS SIMILAR TO HUMAN SPEECH AND EVEN INTEGRATED CIRCUITS THAT PERMIT THE COMPUTER TO SEND COMPUTER DATA ON. A TELEPHONE LINE.

С опорой на рассмотренный алгоритм выделяются необходимые переменные и составляется программа автоматического реферирования и аннотирования.