

УДК 519.766

НОВЫЕ АСПЕКТЫ МЕТОДА ИНДУКТИВНОЙ РЕКОНСТРУКЦИИ
ГРАММАТИК

М.К.Тимофеева

I. В [1] описан метод индуктивной реконструкции грамматик, позволяющий осуществлять переход вида $\langle T, S \rangle \rightarrow G$, где T - текст, S - система априорных знаний о языке, породившем текст T, G - формальное описание этого языка. Этот метод, как он реализован в [1], предполагает наличие в тексте определенных выделенных символов-разделителей. В рассматривавшихся текстах естественных языков это - пробелы и знаки пунктуации. В других текстах не всегда можно выделить такие символы. Например, в генетических текстах - упорядоченные последовательности мономеров (нуклеотидов или аминокислот) - роль знаков пунктуации выполняют не одиночные символы, а их последовательности [2].

В данной статье предлагается модификация метода [1], адаптированная к анализу текста без разделителей. Эта модификация позволила расширить возможности метода [1] и в другом отношении: перейти от выявления грамматической системы, задающей линейные характеристики подцепочек текста, к выявлению грамматической системы, задающей нелинейную структуру таких цепочек и отражающую взаимообусловленность подцепочек текста, расположенных на расстояниях друг от друга.

Прежде чем анализировать тексты неизвестных языков, следует проверить качество работы предлагаемого варианта метода реконструкции на текстах какого-либо известного языка, например, естественного. Эксперименты, проведенные на текстах русского языка, показали, что грамматические структуры, выявляемые на этих текстах, являются осмысленными с позиции традиционной грамматики русского языка.

2. Система S априорных знаний о языке, породившем анализируемый текст, формируется из заданного множества элементарных предположений. Это множество является открытым, т.е. может по мере необходимости пополняться новыми предположениями. В данной статье предлагается расширение системы элементарных предположений, сущность которого можно пояснить следующим образом.

В [I] объектами исследования были только цепочки, представляющие собой осмысленное целое с позиции рассматриваемого языка (при анализе текста естественного языка это – словоформы – отрезки текста от пробела до пробела). В таком случае: а) анализируемая цепочка всегда состоит из целого числа грамматических единиц; б) всегда ясно, какую цепочку можно выбрать в качестве объекта анализа и какие вхождения этой цепочки в текст следует при таком анализе учитывать.

В предлагаемой модификации метода [I] объектом анализа может быть произвольная подцепочка $w = a_1 \dots a_k$ заданного текста (a_1, a_2, \dots, a_k – символы алфавита). Такая подцепочка может не представлять собой осмысленного целого. В частности, w может состоять из нецелого числа языковых единиц. В этом случае предлагается анализировать ее подцепочки с "плавающими" левой и правой границами (последовательность анализируемых подцепочек w_i^j иллюстрируется рис. I). Принципы анализа каждой цепочки w_i^j аналогичны использованным в [I]. Дополнение системы S состоит во введении предложений об интерпретации соотношений между результатами анализа всех цепочек w_i^j ($1 \leq i \leq k-1, 1 \leq j \leq k, i < j$) для заданной цепочки w .

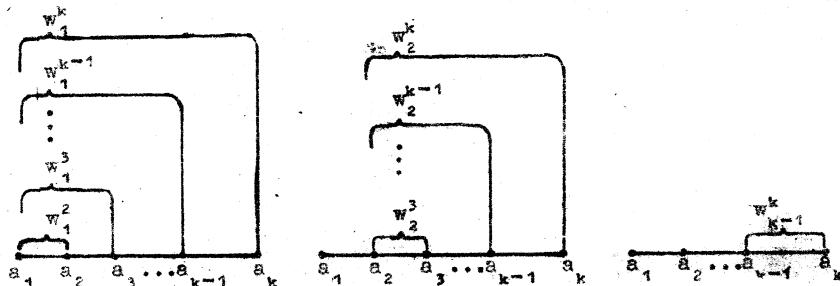


Рис. I

Предлагаемое расширение системы S несколько меняет сам принцип анализа текста. Метод [I] позволяет выявить грамматику, задающую правила комбинирования грамматических единиц в данном тексте. Это - характеристика текста в целом, не отражающая процесса его восприятия. Реально текст воспринимается не в целом, а читается последовательно символ за символом. Прочитанная часть текста служит основанием для некоторого прогноза относительно последующей его части. Использование "плавающих" границ анализируемой цепочки позволяет проследить изменение ожидаемой структуры при продвижении по тексту слева направо и выявить влияние каждого символа заданной цепочки на структуру остальной части этой цепочки.

3. Для формального описания предлагаемой в статье модификации метода [I] введем некоторые обозначения и определения.

У словные обозначения:

A - алфавит;

A^* - множество всех цепочек в алфавите A ;

λ - пустая цепочка;

T - заданный текст в алфавите A ;

w - цепочка, структура которой исследуется, w - подцепочка T , $w = a_1 \dots a_k$, $a_i \in A$, $1 \leq i \leq k$;

$n_i(w)$ - частота встречаемости в тексте T цепочки, совпадающей с первыми i символами цепочки w ;

$w_s^a = \{w_i = a_1 a_{i+1} \dots a_k | 1 \leq i \leq s\}$, где $0 < s < k$.

Определения:

Символ a_i цепочки w называется неинформативным, если $n_{i-1}(w) = n_i(w)$, т.е. за цепочкой $a_1 \dots a_{i-1}$ в тексте T всегда следует символ a_i . Символ a_i цепочки w называется информативным, если $n_{i-1}(w) \neq n_i(w)$, т.е. за цепочкой $a_1 \dots a_{i-1}$ в тексте T не всегда следует символ a_i .

Сегментация цепочки w есть цепочка $I_w = \sigma_1 g_1 \sigma_2 g_2 \dots \sigma_f g_f$, где

$$\sigma_i = \begin{cases} "+", & \text{если } g_i \text{ - информативные символы } w; \\ "-", & \text{если } g_i \text{ - неинформативные символы } w; \end{cases}$$

$w = g_0 g_1 g_2 \dots g_f$, $\sigma_i \neq \sigma_{i+1}$ ($1 \leq i < f$), $\sigma_1 = "-"$, цепочка g_0 состоит только из информативных символов цепочки w . Цепочка g_0 будет называться исходной цепочкой для сегментации I_w ; цепочки g_1 , для которых $\sigma_1 = "+"$, - информативными зонами; цепочки g_1 ; для которых $\sigma_1 = "-"$, - неинформативными зонами.

ПРИМЕР I. Рассмотрим цепочку \tilde{w} из текста $T = INF$ (текст научно-технических рефератов длиной ~ 3500 символов):

$\tilde{w} = \text{ВЫЧИСЛИТЕЛЬНЫЕ ЦЕНТРЫ КОЛЛЕКТИВНОГО ПОЛЬЗОВАНИЯ.}$

Сегментация цепочки \tilde{w} имеет вид:

$I_{\tilde{w}} = -ИСЛІТЕЛЬН+Ы-Е+Ц-ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ,$

исходная цепочка $w_0 = \text{БЫЧ.}$

Цепочка w не сегментируется, если $I_w = \Lambda$. Как видно из предыдущего примера, цепочка "БЫЧ" не сегментируется.

Построим множество цепочек $W_w^s = \{w_1, \dots, w_s\}$, содержащее только сегментируемые цепочки, такое, что цепочка $a_{s+1} a_{s+2} \dots a_k = w_{s+1}$ (состоящая из последних $k-s$ символов цепочки w) не сегментируется. Каждой цепочке $w_i \in W_w^s$ соответствует своя сегментация I_{w_i} со своей исходной цепочкой v_i .

Обозначим через J_w множество сегментаций цепочек из W_w^s . При выявлении структуры цепочки w элементы множества J_w рассматриваются в порядке возрастания индекса i , т.е. сначала I_{w_1} , затем I_{w_2} и т.д. В приложении приведен пример автоматического построения множества $J_{\tilde{w}}$ для цепочки \tilde{w} из примера I. Каждая строка машинной распечатки содержит один элемент из $J_{\tilde{w}}$.

Рассмотрим некоторую сегментацию $I_w = a_1 g_1 \dots a_t g_t \in J_w$. Устойчивость информативной зоны $g_1 = a_{j_1} \dots a_{j_v}$ ($a_j \in A$, $j_1 \leq j_1 \leq j_v$) есть число элементов множества J_w , в которых цепочка $a_{j_1} \dots a_{j_v}$ является информативной зоной. Например, устойчивость информативной зоны $g_1 = a_{13} = \text{"Ы"}$ цепочки \tilde{w} равна 8 (см.приложение).

Пусть $I_{w_1}, I_{w_{1+1}}$ - две сегментации из J_w . Если элемент a_i содержится в обеих сегментациях и в $I_{w_{1+1}}$ он информативен, а в I_{w_1} - нет, то будем говорить, что a_1 влияет на a_i (например, элемент $a_{14} = \text{"Е"}$ цепочки \tilde{w} влияет на элемент $a_{20} = \text{"И"}$ той же цепочки).

4. Предлагаемый в статье метод анализа текста состоит во введении следующих элементарных предположений о языке, породившем этот текст.

I. Граница, разделяющая структурные единицы цепочки w , проходит непосредственно слева от элемента a_i ($i > 2$), если в J_w имеется сегментация I_{w_j} такая, что a_i в ней информативен, а a_{i-1} - нет.

П. Граница, разделяющая структурные единицы цепочки w , проходит непосредственно справа от элемента e_i ($i > 1$), если в сегментации $I_{w_{i+1}}$ существует информативная зона, все элементы которой в сегментации I_{w_1} являются неинформативными.

Ш. Структурная единица e_q связана со структурной единицей $e_{q'}$ цепочки w , если некоторый символ цепочки e_q влияет на некоторый символ цепочки $e_{q'}$.

ПРИМЕР 2. Цепочка \tilde{w} из примера I может быть разделена на структурные единицы следующим образом:

ВЫЧИСЛ/ИТЕЛЬН/ЫЕ/ЦЕНТР/Ы/КОЛЛЕКТИВНО/ГО/ПОДЪЗОВ/А/НИ/Я.

$e_1 \ e_2 \ e_3 \ e_4 \ e_5 \ e_6 \ e_7 \ e_8 \ e_9 \ e_{10} \ e_{11} \ e_{12}$

Границы между e_1 и e_2 , e_6 и e_7 выделены по предположению П; границы между e_2 и e_3 , e_3 и e_4 , e_5 и e_6 , e_7 и e_8 , e_8 и e_{10} , e_{10} и e_{11} , e_{11} и e_{12} выделены по предположению I; границы между e_4 и e_5 , e_8 и e_9 могут быть выделены по обоим указанным предположениям.

ПРИМЕР 3. Единица e_4 = "НЕ", выделенная в цепочке \tilde{w} , связана с единицей e_6 = "Ы", e_6 , в свою очередь, связана с единицей e_8 = "ГО", а e_8 - с единицей e_{12} = "Я", т.е. все окончания приведенного словосочетания оказываются последовательно связанными. На распечатке связи между структурными единицами обозначены стрелками.

Заданной цепочке w сопоставляется структура вида $Z_w = \langle E_w, P_w \rangle$, где E_w - набор структурных единиц w , выделенных по предположению I или П, P_w - отношение связанности между элементами w , установленное на основании предположения Ш.

Предположения I-Ш включены в систему элементарных предположений, описанную в [1]. При нахождении информативных и неинформативных зон использовались полные спектры 1-грамм [3] - списки частот встречаемости в заданном тексте различных его подцепочек длиной в 1 символов. Бместо полных спектров 1-граммы могут использоваться частичные спектры, программы получения которых описаны в [4].

5. В приложении приведены примеры машинных распечаток, полученные на тексте научно-технических рефератов IMF (анализ текста слева направо и справа налево) и общественно-политическом тексте РОЛ русского языка (~ 4000 символов), а также, для сравнения, - на генетическом тексте SV40 (~ 6000 символов).

По приведенным распечаткам видно, что границы разделения единиц в естественно-языковых текстах почти всегда имеют лингвистическое основание и соответствуют границам между морфами. Ошибки в проведении таких границ, как правило, объясняются опечатками в тексте. Таковы, например, разделение

"ВЫЧИСЛИТЕЛЬНЫЕ ЦЕНТРЫКОЛ/ЛЕКТИВНОГО ПОЛЬЗОВАНИЯ",
полученное при анализе цепочки \tilde{w} справа налево, и разделение
"ПРОЛЕТАРСКОГО ИН/ТЕРНАЦИО/НАЛИЗМА",
полученное при анализе подцепочки

$\delta = \text{ПРОЛЕТАРСКОГОИНТЕРНАЦИОНАЛИЗМА}$

текста POL слева направо (здесь указаны не все разделения цепочек \tilde{w} и δ). Выявленные связи между единицами также отражают действительные отношения, свойственные данному тексту. Они связывают как морфы внутри слов (например, ВЫ \rightarrow ИТЕЛЬН), так и морфы разных слов (например, цепочка согласующихся окончаний НЕ \rightarrow И \rightarrow ГО \rightarrow Я).

Если проводить чисто формальное сопоставление результатов анализа естественно-языковых и генетических текстов (не учитывая семантику этих текстов), то можно обнаружить следующие различия:

Сегментации естественно-языковых текстов сложнее. Как правило, они содержат несколько информативных зон. Сегментации генетических текстов обычно имеют более простое строение вида $I_{\tilde{w}} = -g_1$ (в g_1 все символы неинформативны). Для естественно-языковых текстов характерны большая устойчивость информативных зон и большие длины исходных цепочек.

Применение описанного в статье метода реконструкции к анализу слитного текста позволило выявить ряд сложностей:

1) выбор способа совмещения результатов анализа текста слева направо и справа налево (как видно из приведенного в приложении примера, эти результаты в общем случае расходятся);

2) нахождение способа отбора анализируемых подцепочек при необходимости построения структуры всего текста (а не отдельных его подцепочек, как было описано выше);

3) создание программных средств, обеспечивающих возможность работы с текстами, спектры 1-грамм которых не помещаются целиком в оперативную память.

6. Помимо задачи анализа слитного текста неизвестного языка, описанный метод может служить средством решения ряда других задач.

Каждая группа информативных символов важна для восприятия всей анализируемой цепочки. По последовательности информативных зон можно однозначно восстановить всю оставшуюся часть цепочки. Это свойство может быть использовано при выборе экономной кодировки или при восстановлении испорченных частей подцепочек текста. Изменение информативных и неинформативных зон при последовательном (по мере возрастания i) анализе сегментаций из I_w позволяет строить структуры, отражающие динамику восприятия цепочки w (на рис.2 приведена часть структуры, определяющей динамику восприятия цепочки \tilde{w} в тексте INF). Стрелка вида:

$$\boxed{a_j a_{j+1} \dots a_{j+p}} \rightarrow \boxed{a_{j+m} \dots a_{j+m+r}}$$

на рис.2 означает: а) в сегментации I_w^{j+p+1} цепочка $v = a_{j+m} \dots a_{j+m+r}$ либо является частью информативной зоны, либо входит в состав исходной цепочки для I_w^{i+p+1} ; б) в сегментации I_w^{j+p} цепочка — часть неинформативной зоны; в) сегментации $I_w^{j-1}, \dots, I_w^{j+p}$ совпадают и отличны от сегментации I_w^{j-1} ($1 < j < k$). Иначе говоря, структура, приведенная на рис.2, позволяет определить, какие элементы цепочки \tilde{w} однозначно предсказывают появление цепочки v .

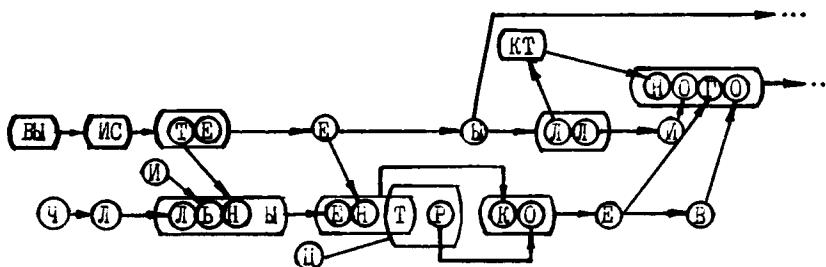


Рис. 2

Если из текста не были выброшены пробелы (как в приведенных примерах), то можно использовать их при интерпретации результата.

Это позволит: а) выделять связи между морфами одного слова и морфами соседних слов; б) прослеживать согласованность соседних слов в разных формах, выделяя тем самым устойчивые для данного текста конструкции слов.

Сложность применения описанного в статье варианта метода реконструкций к анализу больших текстов ограничивает возможности его использования при исследовании языковых особенностей текстов того или иного подъязыка естественного языка (основное назначение метода [1]). Метод, описанный в [1], требовал анализа больших текстов и его применение было затруднено сложностью введения этих текстов в ЭВМ. Модификация, предлагаемая в данной статье, дает наглядные результаты на текстах небольшой длины (3-5 тысяч символов или 1-2 страницы), что дает возможность ее более широкого использования при исследовании структуры отдельных участков текста.

Л и т е р а т у р а

1. ТИМОФЕЕВА М.К. О методике индуктивной реконструкции грамматик. -Новосибирск, 1983. Б.и. - 18 с. (Препринт/ИМ СО АН ССР: № 40)
2. ГУСЕВ В.Д., КУЛИЧКОВ В.А., ТИТКОВА Т.Н. Анализ генетических текстов. I. 1-граммные характеристики. -В кн.: Эмпирическое предсказание и распознавание образов (Вычислительные системы, вып. 63). Новосибирск, 1980, с. 11-33.
3. ГУСЕВ В.Д., КОСАРЕВ Ю.Г., ТИТКОВА Т.Н. О задаче поиска повторяющихся отрезков текста. -В кн.: Вычислительные системы, вып. 62. Ассоциативное кодирование. -Новосибирск, 1975, с.49-71.
4. ТИМОФЕЕВА М.К. Применение В-технологии программирования для организации больших словарей в памяти ЭВМ. -В кн.: Автоматизированные системы управления БУЗом. Новосибирск, 1978, с.57-66.

Поступила в ред.-изд.отд.
21 августа 1985 года

ПРИЛОЖЕНИЕ

Множество сегментаций, полученное при анализе цепочки \tilde{w}
из текста научно-технических рефератов слева направо

ВЕС - ИСПИТЕЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЧИС - ИСПИТЕЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЧИС- А+ И- ТЕЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ИЛИ- ТЕЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	СЛИ- ТЕЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЛИТЕ- ЛЬН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ИТЕЛ- БЫ+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ТЕЛЬ- МН+ У- Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЕЛЬН+ Е+ Ц- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЛЬНКЕЦ- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	БННЕЦ- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
НЬЕЦ- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	КЕЦ- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЕЦЕ- ЕНТРЫКОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЦЕН- ТР+ У- П- КОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЧЕН- ТР+ У- П- КОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЕНТРЫ- КОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
НТРЫ- КОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	НТРЫ- КОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
РЫК- ОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ	РЫК- ОЛЛЕКТИВНОГОПОЛЬЗОВАНИЯ
ЫКО- ПЛЕКТИВНОГОПОЛЬЗОВАНИЯ	ЫКО- ПЛЕКТИВНОГОПОЛЬЗОВАНИЯ
КОЛЛ- ЕКТИВНО+ Г- 0+ П- ОЛЬЗОВАНИЯ	ОЛЛ- ЕКТИВНО+ Г- 0+ П- ОЛЬЗОВАНИЯ
АЛЛ- ЕКТИВНО+ Г- 0+ П- ОЛЬЗОВАНИЯ	АЛЕ- КТИВНО+ Г- 0+ П- ОЛЬЗОВАНИЯ
ЛЕКТ- ИНО+ Г- 0+ П- ОЛЬЗОВАНИЯ	ЛЕКТ- ИНО+ Г- 0+ П- ОЛЬЗОВАНИЯ
ЕКТИ- ЭНО+ Г- 0+ П- ОЛЬЗОВАНИЯ	КТИВ- НО+ Г- 0+ П- ОЛЬЗОВАНИЯ
ТИВ- НО+ Г- 0+ П- ОЛЬЗОВАНИЯ	ИВН- 0+ Г- 0+ П- ОЛЬЗОВАНИЯ
ВНЭГ- 0+ П- ОЛЬЗОВАНИЯ	
МОГОПО- ЛЬЗОВАНИЯ	
ЗГОПО- ЛЬЗОВАНИЯ	
ГОПО- ЛЬЗОВАНИЯ	
ОПО- ЛЬЗОВАНИЯ	
ПОЛЬ- ЗОВА+ Н- ИФ Я	
ОЛЬЗ- ОВА+ Н- ИФ Р	
ЛЬЗ- ОВА+ Н- ИФ Я	
БЗ- ОВА+ Н- ИФ Я	
ЗО- В+ АН- ИФ Я	

I_EF1421 - STEP WAS EXECUTED - COND CODE 6592

I_EF3741 STEP /CO / START 05242.0205
I_EF3741 STEP /CO / STOP 05242.0205 CPU 0M1N 22.605SEC MAIN 94K

Множество сегментаций, полученное при анализе цепочки ~
из текста научно-технических рефератов справа налево

ЯИНАВ- 0+ 3- ьЛОП+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕГИЛСИЧИВ
ИНАВ- 0+ 3- ьЛОП+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕГИЛСИЧИВ
НАВ- 0+ 3- ьЛОП+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ

АВОЗ- ьЛОГ+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ВОЗЬ- ьЛОГ+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ОЗЬ- ьЛОГ+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЗЬ- ьЛОГ+ 0- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЬЛОГО- ГОНВИТКЕЛ+ А- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЛОПС- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ОЛО- ГОНВИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ПОГ- ОН+ В- ИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ

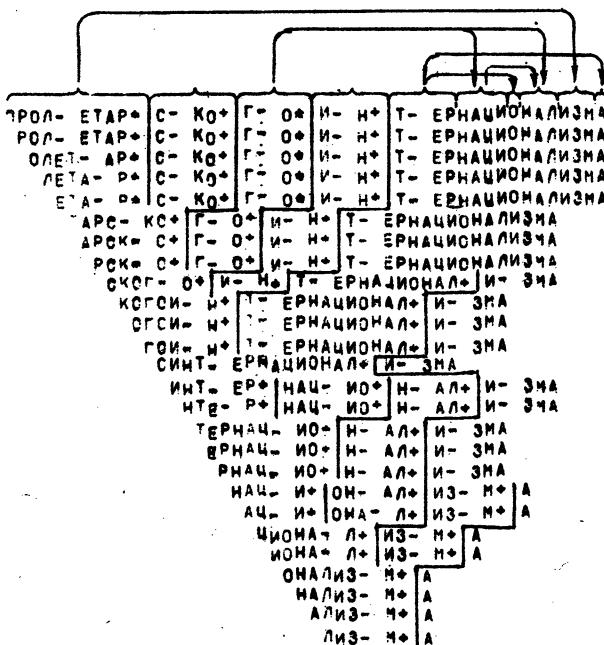
ОГОНЬ- ИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ГОНВ- ИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ОНВИ- ИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
НВИ- ИТКЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ВИТ- КЕЛ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ИТКЕТ- ЛОГ+ Л- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ТКЕЛА- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
КЕЛА- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЕЛА- ОК+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЛОГ- К+ ы- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ЛОКИ- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ОКУ- РТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
КИР- ТНЕЦЕНЬНЛЬЕТИЛСИЧИВ
ИРТ- НЕЦЕНЬНЛЬЕТИЛСИЧИВ
РТН- ЕИ+|Е- ЫНЬЛЕТИЛСИЧИВ
ТНЕЧЕ- ЫНЬЛЕТИЛСИЧИВ
НЕЧЕ- ЫНЬЛЕТИЛСИЧИВ
ЕЧЕ- ЫНЬЛЕТИЛСИЧИВ
ЧЕЧ- ЫНЬЛЕТИЛСИЧИВ
ЕНИ- ЛЕТИЛСИЧИВ
ИНЬ- ЛО|Е- Т+|И- ЛОИЧИВ
ИНЬ- ЛО|Е- Т+|И- ЛОИЧИВ
ЬЛЕТИ- ЛСИЧИВ
ЛЕТИ- ЛСИЧИВ
ЕТИЛ- СИЧИВ
ТИЛС- АЧИВ
ИЛС- ИЧИВ
АСИ- Ч+|У- В
СИЧУ- З
ИЧИУ- З

EF1421 - STEP WAS EXECUTED - COND CODE 4888

EF3731 STEP /GO / START 85240.2341

EF3741 STEP /GO / STOP 85240.2342 CPU WIN 20.70SEC MAIN 93K

Множество сегментаций, полученное при анализе цепочки из общественно-политического текста слева направо



EE1421 - STEP WAS EXECUTED - CONC CODE 4096

EE37'1 STEP /60 / START 95240.2335

STEP // STOP // START // 052248.2348 CPU 1MIN 25.38SEC MAIN 82K

Множество сегментаций, полученное при анализе цепочки из генетического текста SV40 слева направо

TGGTTG- CTGACTAATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GTTGCT- GACTAATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GTTGCTG- ACTAATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TTGCTGA- CTAATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TGCTG- CTAATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GCTGACT- AATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
CTGACT- AATTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TGACTAA- TTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GACTAA- TTGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
ACTAAT- TGAGATGCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
CTAATTG- GATGCAATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TAATTG- GATGCAATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
AATTGAG- ATGCAATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
ATTAG- ATGCAATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TTGAGAT- GCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
TGAGAT- GCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GAGAT- GCATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
AGATGC- ATGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
GATGCA- TGCTTGCATACTTCTGCCCTGCTGGGGAGCCTGG
ATGCAATG- CTTPGCATACTTCTGCCCTGCTGGGGAGCCTGG
TGCATG- CTTPGCATACTTCTGCCCTGCTGGGGAGCCTGG
GCATGC- TTTCATACTTCTGCCCTGCTGGGGAGCCTGG
CATGCTT- GCATACTTCTGCCCTGCTGGGGAGCCTGG
ATGCTT- CATACTTCTGCCCTGCTGGGGAGCCTGG
TGCTT- CATACTTCTGCCCTGCTGGGGAGCCTGG
GCTCTT- CATACTTCTGCCCTGCTGGGGAGCCTGG
CTTTCAT- ACTTCTGCCCTGCTGGGGAGCCTGG
TTTGCAT- A+|C- TTCTGCCTGCTGGGGAGCCTGG
TTGCATAC- T+|T- CTGCCTGCTGGGGAGCCTGG
TGCATAC- T+|T- CTGCCTGCTGGGGAGCCTGG
GCATAC- T+|T- CTGCCTGCTGGGGAGCCTGG
CATACTT- CTGCCTGCTGGGGAGCCTGG
ATACTTC- CTGCCTGCTGGGGAGCCTGG
TACTTC- T+|GCC- TGCTGGGGAGCCTGG
ACTTCTGCC- TGCTGGGGAGCCTGG
CTTCTGCC- TGCTGGGGAGCCTGG
TTCTGCC- TGCTGGGGAGCCTGG
TCTGCC- TGCTGGGGAGCCTGG
CTGCCCTG- CTGGGGAGCCTGG
TGCTGCC- TGGGGAGCCTGG
GCTCTG- GGGGAGCCTGG
CTGCTG- GGAGCCTGG
CTGCTGGG- GAGCCTGG
TGCTGGGG- AGCCTGG
GCTGGGG- AGCCTGG
CTGGGGAG- CCTGG
TGGGGAG- CCTGG
GGGGAGC- CTGG
GGGAGC- CTGG
GGAGCC- TGG
GAGCC- T+|GG

IEF1421 - STEP NAS EXECUTED - COND CODE 5200

IEF1421 - STEP WAS EXECUTED - COMM CODE
IEF3231 STEP /GO / START 85240,2342

IEF3741 STEP /GO // START 05240-2347 STOP 85240-2349 CPU 1MIN 23.00SEC MAIN 94K