

Санкт-Петербургский государственный университет

**ОЛЬХОВСКИЙ Илья Сергеевич  
Выпускная квалификационная работа**

**Сложность преобразования LL( $k$ ) линейных грамматик и  
конъюнктивных LL( $k$ ) линейных к LL(1) линейным**

Образовательная программа бакалавриат «Математика»

Направление и код: 01.03.01 «Математика»

Шифр ОП: СВ.5000.2016

Научный руководитель:  
профессор  
факультета математики  
и компьютерных наук СПбГУ  
к.ф.-м.н., Ph.D.  
А. С. Охотин

Рецензент: доцент  
математико-механического  
факультета СПбГУ  
к.ф.-м.н.  
С. В. Григорьев

Санкт-Петербург  
2020 год

# Содержание

<b>1 Введение</b>	1
<b>2 Основные определения</b>	2
<b>3 План преобразования линейной LL(<math>k</math>) грамматики к виду LL(1)</b>	<b>6</b>
<b>4 Устранение «коротких» правил</b>	<b>8</b>
<b>5 Приведение к виду LL(1)</b>	<b>14</b>
<b>6 Нижняя оценка</b>	<b>24</b>
<b>7 Конъюнктивные линейные LL(<math>k</math>) грамматики</b>	<b>31</b>
<b>8 Конъюнктивные грамматики: устранение «коротких» правил</b>	<b>35</b>
<b>9 Конъюнктивные грамматики: приведение к виду LL(1)</b>	<b>40</b>
<b>10 Заключение</b>	<b>49</b>

## 1 Введение

LL( $k$ )-анализ — один из самых известных методов синтаксического анализа, работающих за линейное время. В этом методе дерево разбора последовательно восстанавливается сверху вниз, по мере чтения строки слева направо. При этом нужное правило вывода синтаксический анализатор выбирает, заглядывая вперёд не более, чем на  $k$  символов. Класс LL( $k$ ) грамматик, к которому он применим, был изучен в работах Кнута [1971], Льюиса и Стирнса [1968], Розенкранца и Стирнса [1970]. При этом Розенкранц и Стирнс, а также Курки-Суонио [1969] установили, что, для всякого  $k$ , грамматики из класса LL( $k+1$ ) порождают больше языков, чем грамматики из класса LL( $k$ ), и таким образом появляется иерархия классов *LL* грамматик.

Важный подкласс *линейных LL( $k$ ) грамматик* впервые изучался Ибаррой и др. [1988] и Хольцером и Ланге [1993], получивших ряд результатов о вычислительной сложности языков, задаваемых такими грамматиками. Однако очевидный вопрос о существовании иерархии классов LL( $k$ )-линейных грамматик остался нерассмотренным.

В данной работе даётся отрицательный ответ на этот вопрос: оказывается, что в линейном случае иерархия по  $k$  обрушивается, то есть все

языки, задаваемые грамматиками из класса LL( $k$ )-линейных для некоторого  $k$ , задаются и грамматиками из класса LL(1)-линейных. Доказательство проводится эффективным преобразованием, состоящем из двух этапов и описанном в разделах 3–5: на первом этапе произвольная LL( $k$ )-линейная грамматика преобразуется к некоторому нормальному виду, а на втором этапе — далее к LL(1)-линейной.

Полученное построение приводит к сильному росту числа нетерминальных символов грамматики: их становится больше примерно в  $|\Sigma|^{2k}$  раз, где  $\Sigma$  — алфавит языка. Поэтому естественным образом возникает вопрос об эффективности приведённого построения и о нижней оценке количества нетерминальных символов LL(1)-линейной грамматики, задающей тот же язык, что и данная LL( $k$ )-линейная. Нельзя ли разработать другое, улучшенное построение, которое не будет приводить к столь значительному росту?

Оказывается, что нет. В разделе 6 устанавливается, что такой рост количества нетерминальных символов неизбежен, и приводимое построение на самом деле близко к оптимальному: строятся примеры LL( $k$ )-линейных грамматик с  $n$  нетерминальными символами, для которых доказывается, что всякая LL(1)-линейная грамматика, задающая тот же язык, должна иметь не менее чем  $n \cdot |\Sigma|^{2k-O(\log k)}$  нетерминальных символов.

Третий результат этой работы посвящён более мощному классу формальных грамматик — *конъюнктивным грамматикам*. Конъюнктивные грамматики, введённые Охотиным [2001], обобщают обычные грамматики введением операции конъюнкции в правила. Для них также определены LL( $k$ )-подкласс и линейный подкласс, и, таким образом, можно рассматривать *LL( $k$ )-линейные конъюнктивные грамматики*; их определение приведено в разделе 7. Ранее Охотин [2011] определил простейшие ограничения выразительной мощности этого подкласса, но в целом класс остаётся малоизученным. В частности, вопрос о существовании иерархии по  $k$  не рассматривался.

В разделах 8–9 этой работы установлено, что LL( $k$ )-линейные конъюнктивные грамматики можно перевести в LL(1)-линейные конъюнктивные. Результат доказывается обобщением построения для случая обычных грамматик.

Результаты разделов 3–6 данной работы представлены в двух статьях, опубликованных в сборниках докладов конференций RuFiDiM 2019 и CSR 2020.

## 2 Основные определения

**Определение 1.** *Линейной (формальной) грамматикой называется четвёрка  $G = (\Sigma, N, R, S)$ , состоящая из следующих компонентов:*

1.  $\Sigma$  — конечное множество символов, называемое **алфавитом**.
2.  $N$  — конечное множество **нетерминалов**. Каждый нетерминал обозначает некоторое свойство, которым строка из  $\Sigma^*$  может обладать или не обладать.
3.  $R$  — конечное множество **правил грамматики**, каждое из которых описывает возможную структуру строк со свойством  $A \in N$ . Каждое правило имеет вид  $A \rightarrow w_1Bw_2$ , где  $B \in N$  — нетерминал, а  $w_1, w_2 \in \Sigma^*$  — строки, или вид  $A \rightarrow x$ , где  $x \in \Sigma^*$ . Правило  $A \rightarrow x$  означает, что строка  $x$  обладает свойством  $A$ , а наличие правила  $A \rightarrow w_1Bw_2$  означает, что если строка  $s$  обладает свойством  $B$ , то строка  $w_1sw_2$  обладает свойством  $A$ .
4.  $S \in N$  — выделенный **начальный нетерминал**.

**Определение 2.** Деревом разбора линейной грамматики  $G = (\Sigma, N, R, S)$  называется упорядоченное корневое дерево, листья которого помечены символами алфавита  $\Sigma$ , а внутренние вершины — нетерминальными символами из  $N$ . Если внутренняя вершина помечена нетерминалом  $A \in N$ , а её потомки — символами  $X_1, \dots, X_l \in \Sigma \cup N$ , то в грамматике должно присутствовать правило  $A \rightarrow X_1 \dots X_l$ . Так как среди потомков  $X_1 \dots X_l$  не более одного является нетерминалом, то дерево разбора представляет из себя путь из нетерминальных вершин, от которых влево и вправо отходят листья, как показано на рисунке 1(слева).

Пусть  $w$  — строка из символов всех листьев, а  $A \in N$  — нетерминал, которым помечен корень. Тогда соответствующее дерево разбора называют **деревом разбора  $w$  из  $A$** .

**Язык, задаваемый нетерминалом  $A$ ,** определяется как множество всех строк  $w$ , для которых существует дерево разбора  $w$  из  $A$ . Мы будем обозначать его  $L_G(A)$  или  $L(A)$ , если ясно, о какой грамматике идёт речь.

**Язык, задаваемый грамматикой,** определяется как язык, задаваемый её начальным нетерминалом  $S$ . Мы будем обозначать его  $L(G)$ .

**Замечание 1.** Если нетерминал, которым помечен корень дерева разбора, не указан явно, то подразумевается, что им является начальный нетерминал  $S$ .

**Замечание 2.** Пусть в дереве разбора  $w$  из  $A$  к корню применяется правило  $A \rightarrow \alpha$ . Тогда будем говорить, что в этом дереве разбора  $A$  задаёт  $w$  по правилу  $A \rightarrow \alpha$ .

**Замечание 3.** Мы будем допускать некую вольность речи и писать "поддерево, помеченное  $A$ " или просто "поддерево  $A$ " имея в виду "поддерево, корень которого помечен нетерминалом  $A$ ".

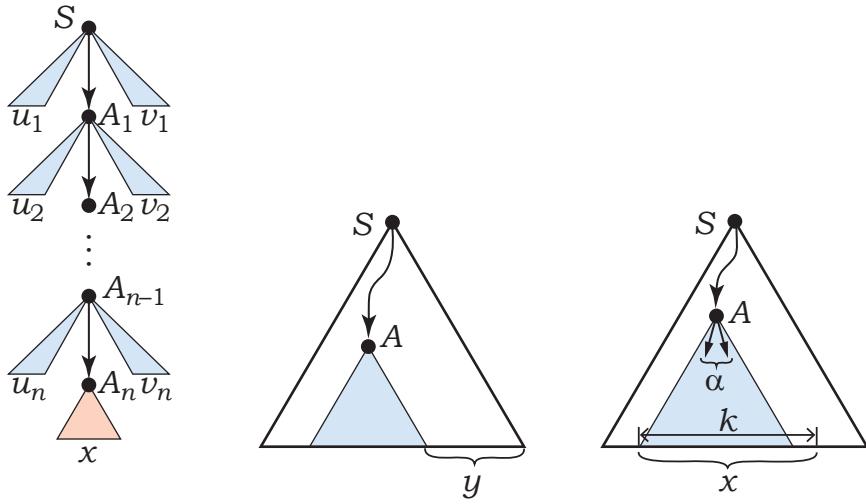


Рис. 1: Слева направо: дерево разбора линейной грамматики, иллюстрация к определению  $\text{Follow}(A)$ , иллюстрация к определению LL-таблицы

**Определение 3.** Пусть  $G = (\Sigma, N, R, S)$  – формальная грамматика.

Пусть зафиксировано некоторое дерево разбора  $G$  и поддерево в нём.

Будем говорить, что строка  $y \in \Sigma^*$  **следует** за этим поддеревом, если все листья справа от поддерева образуют строку  $y$ .

Будем говорить, что  $y$  **следует за нетерминалом**  $A \in N$ , если существует поддерево некоторого дерева разбора, помеченное символом  $A$ , за которым следует  $y$ , как на рисунке 1 (в середине).

Обозначим:

$$\text{Follow}(A) = \{ v \mid v \text{ следует за } A \}$$

Синтаксическим анализом строки называется построение дерева разбора этой строки. Класс грамматик  $\text{LL}(k)$ , рассматриваемый в этой работе, допускает синтаксический анализ за линейное время с помощью специального алгоритма.

Сначала будет описан этот алгоритм, а потом уже точно определён класс  $\text{LL}(k)$ .

**Определение 4.** **Синтаксическим анализатором** для линейной  $\text{LL}(k)$  грамматики  $G = (\Sigma, N, R, S)$  называется алгоритм, который по данной строке  $w$  строит её дерево разбора.

Строка  $w$  при этом читается слева направо, а дерево разбора строится сверху вниз.

На каждом шаге **состоянием** (или **конфигурацией**) алгоритма является пара  $(uAv, x)$ , где  $x \in \Sigma^*$  – ещё не разобранный суффикс строки

ки  $w$ , а  $uAv$ , где  $A \in N$ ,  $u, v \in \Sigma^*$ , — содержимое стека синтаксического анализатора.

Инвариантом алгоритма является то, что строка  $w$  задаётся грамматикой тогда и только тогда, когда строка  $x$  представима в виде конкатенации  $uyv$ , где  $y \in L(A)$ .

В начале работы алгоритм находится в состоянии  $(S, w)$ .

На каждом шаге алгоритм видит символ на вершине стека и первые  $k$  символов строки  $x$ .

Если на вершине стека находится символ алфавита  $a \in \Sigma$ , и конфигурация анализатора имеет вид  $(auAv, x)$ , синтаксический анализатор проверяет, что строка  $x$  начинается с  $a$ , и если так и есть, то переходит в конфигурацию  $(auAv, x')$ , где  $ax' = x$ , а если  $x$  пусто или начинается с другого символа, то выдаёт ошибку.

Если же на вершине стека находится нетерминал  $A \in N$ , и конфигурация анализатора имеет вид  $(Av, x)$ , синтаксический анализатор неким способом, связанным со спецификой класса  $LL(k)$ , определяет правило  $A \rightarrow sBt$ , которое следует применить к нетерминалу  $A$ , и переходит в состояние  $(sBtv, x)$ .

Принадлежность грамматики  $G$  к классу  $LL(k)$  позволяет описанному выше синтаксическому анализатору определять правило, которое следует применить к нетерминалу на вершине стека, путём обращения к специальной таблице:

**Определение 5.**  $LL(k)$ -таблицей для грамматики  $G = (\Sigma, N, R, S)$  называется частично определённая функция  $T : N \times \Sigma^{\leq k} \rightarrow R$ , удовлетворяющая следующему условию.  $T(A, x) = (A \rightarrow \alpha)$ , где  $A \in N, x \in \Sigma^{\leq k}$ , тогда и только тогда, когда существует поддерево некоторого дерева разбора, помеченное нетерминалом  $A$ , такое что первые  $k$  листьев всего дерева, начиная с самого левого листа поддерева, образуют строку  $x$ , и к корню поддерева применяется правило  $A \rightarrow \alpha$ , как показано на рисунке 1(справа).

Если для грамматики  $G$  существует  $LL(k)$ -таблица, и каждый нетерминал  $G$  встречается в некотором дереве разбора, то говорят, что  $G$  принадлежит классу  $LL(k)$ .

Таким образом, если  $G$  принадлежит классу  $LL(k)$ , то для любого поддерева дерева разбора  $G$  правило, применяемое к корню этого поддерева, однозначно определяется строкой, составленной из символов первых  $k$  листьев, начиная с самого левого листа поддерева.

Требование, того чтобы каждый нетерминал грамматики встречался в некотором дереве разбора нужно чтобы исключить "вырожденные грамматики". Если грамматика задаёт хотя бы одну строку, его легко удовлетворив, просто убрав из грамматики все нетерминалы, которые не встречаются ни в одном дереве разбора.

Следовательно, когда синтаксический анализатор находится в состоянии  $(Av, x)$ , он понимает, что к  $A$  следует применить правило  $T(A, x')$ , где  $x'$  — первые  $k$  символов строки  $x$ .

Если  $T(A, x')$  не определено, то анализатор выдаёт ошибку.

**Определение 6.** Пусть  $w \in \Sigma^*$ . Обозначим за  $\text{First}_k(w)$  префикс  $w$  длины  $k$ . Если  $|w| < k$ , то  $\text{First}_k(w) = w$ .

Это обозначение обобщается на языки. Пусть  $L \subseteq \Sigma^*$ . Тогда

$$\text{First}_k(L) = \{ \text{First}_k(w) \mid w \in L \}$$

Далее в доказательствах будет использоваться следующее известное утверждение.

**Факт 1.** Следующие два утверждения эквивалентны.

1. Грамматика  $G = (\Sigma, N, R, S)$  принадлежит классу  $LL(k)$ .
2. Для любого нетерминала  $A \in N$  и для любых двух различных правил  $A \rightarrow \alpha_1$  и  $A \rightarrow \alpha_2$  множества  $\text{First}_k(L_G(\alpha_1)\text{Follow}(A))$  и  $\text{First}_k(L_G(\alpha_2)\text{Follow}(A))$  не пересекаются.

### 3 План преобразования линейной $LL(k)$ грамматики к виду $LL(1)$

Первый результат данной работы состоит в том, что по произвольной линейной  $LL(k)$  грамматике  $G$  можно построить линейную  $LL(1)$  грамматику  $G'$ , задающую тот же язык.

Естественно пытаться определить  $G'$  так, чтобы вывод каждой строки  $w$  в  $G'$  каким-нибудь образом повторял вывод той же строки  $w$  в  $G$ , и, соответственно, каждое вычисление синтаксического анализатора  $G'$  также каким-нибудь образом повторяло аналогичное вычисление синтаксического анализатора  $G$ .

Синтаксический анализатор для исходной грамматики  $G$  определял правило, которое нужно применить на очередном шаге, исходя из первых  $k$  символов ещё не прочитанной части входной строки.

Чтобы повторить вычисление анализатора  $G$ , анализатору  $G'$  тоже необходимо каким-то образом узнать следующие  $k$  символов входной строки.

Основная идея преобразования заключается в использовании *буфера* для не более, чем  $k - 1$  символов: будучи не в силах сразу определить правило, которое следует применить для нетерминала на вершине стека, анализатор продолжает читать символы входной строки, занося их в буфер, пока их не наберётся достаточно, чтобы определить то самое правило.

Реализуется это с помощью введения новых нетерминалов  ${}_u A$ , где  $A \in N$  — нетерминал исходной грамматики, а строка  $u \in \Sigma^{\leq k-1}$  выполняет роль буфера. Каждый нетерминал  ${}_u A$  задаёт язык  $L_{G'}({}_u A) = \{w \mid uw \in L_G(A)\}$ .

Каждому правилу  $A \rightarrow sBt$  грамматики  $G$ , такому, что одна из строк  $u, s$  является префиксом другой, в грамматике  $G'$  соответствует цепочка из  $k$  правил:

$$\begin{aligned} A &\rightarrow u_1 {}_{u_1} A \\ {}_{u_1} A &\rightarrow u_2 {}_{u_1 u_2} A \\ &\vdots \\ {}_{u_1 \dots u_{k-2}} A &\rightarrow u_{k-1} {}_u A \\ {}_u A &\rightarrow \alpha \end{aligned}$$

Первые  $k - 1$  правил наращивают буфер, и когда буфер достигает размера  $k - 1$ , что, вместе с одним символом, доступным анализатору  $G'$  напрямую, даёт необходимые ему  $k$  символов, применяется нужное правило  $\alpha$ . Последнее получается откусыванием уже прочтённой строки  $u$  из начала правила  $A \rightarrow sBt$ : общие префиксы  $u$  и  $s$  сокращаются, и оставшиеся символы  $u$ , если они есть, уходят в буфер нетерминала  $B$ . Таким образом, если  $u = sv$ , то  $\alpha = {}_v Bt$ , а если  $s = us'$ , то  $\alpha = {}_{s'} {}_\epsilon Bt$ . Это проиллюстрировано на рисунках [5](#) и [6](#).

Однако у такого плана есть существенный изъян. Если в исходной грамматике есть *короткое* правило  $A \rightarrow s$ , где  $s \in \Sigma^{<k-1}$ , то синтаксическому анализатору  $G'$ , чтобы определить это правило, может понадобиться занести в буфер не только всю строку  $s$ , но и некоторые символы, идущие после неё, не порождённые нетерминалом  $A$ .

В таком случае в момент, когда анализатор поймёт, что надо применить правило  $A \rightarrow s$ , на вершине его стека будет находиться нетерминал  ${}_{sx} A$ , где  $|x| > 0$ , и удалить буфер  $sx$  из правой части правила  $A \rightarrow s$  будет, очевидно, невозможно.

**Пример 1.** Рассмотрим следующую линейную  $LL(3)$  грамматику.

$$\begin{aligned} S &\rightarrow aabSaa \\ S &\rightarrow a \quad (\text{короткое правило}) \end{aligned}$$

Чтобы понять, какое из этих правил следует применить, гипотетический  $LL(1)$  анализатор заносит в буфер до двух первых символов с помощью следующих правил.

$$\begin{aligned} {}_\epsilon S &\rightarrow a {}_a S \\ {}_a S &\rightarrow a aa S \end{aligned}$$

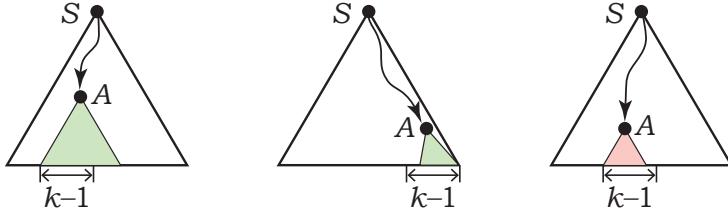


Рис. 2: Третье правило короткое, а первые два — нет.

*Когда в буфере находится строка aa, и анализатор видит, что следующий символ — b, он понимает, что следует применить правило  $S \rightarrow aabSaa$ , и применяет его, предварительно удалив из начала уже прочтённые символы aa.*

$$aaS \rightarrow b_\varepsilon Saa$$

*Однако если анализатор видит, что следующий символ — a, он понимает, что следует применить правило  $S \rightarrow a$ , но совершенно не ясно, чему поставить в соответствие уже прочтённые символы aa.*

Корень проблемы кроется в наличии *короткого правила*, порождающего подстроку длины менее, чем  $k - 1$ , где-то в середине строки.

Далее будет показано, что в случае отсутствия в грамматике коротких правил намеченная конструкция будет работать.

Соответственно, первым шагом преобразования произвольной линейной LL( $k$ ) грамматики к виду LL(1) будет устранение коротких правил.

## 4 Устранение «коротких» правил

**Определение 7.** *Коротким правилом* будем называть правило вида  $A \rightarrow w$ , где  $w \in \Sigma^*$ ,  $|w| < k - 1$  и  $\text{Follow}(A) \neq \{\varepsilon\}$ , как показано на рисунке 2 (справа).

**Лемма 1.** Для каждой линейной LL( $k$ ) грамматики  $G = (\Sigma, N, R, S)$  существует линейная LL( $k$ ) грамматика  $G'$  без коротких правил, задающая тот же язык. Количество нетерминалов  $G'$  не превосходит  $|\Sigma^{\leq k-1}| \cdot |N|$ .

*Доказательство.* Опишем структуру новой грамматики  $G' = (\Sigma, N', R', S_\varepsilon)$ . Нетерминалы  $G'$  имеют вид  $A_u$ , где  $A \in N$  и  $u \in \Sigma^{\leq k-1}$ .

Грамматика  $G'$  будет определена так, что каждый нетерминал  $A_u$  будет задавать все строки, задаваемые  $A$  в  $G$ , с приписанным в конце суффиксом  $u$ :  $L_{G'}(A_u) = \{wu \mid w \in L_G(A)\}$ .

Для каждого нетерминала  $A_u$  и для каждого правила  $A \rightarrow w_1 B w_2 \in R$ , в новой грамматике будет правило  $A_u \rightarrow \alpha$ , определённое ниже.

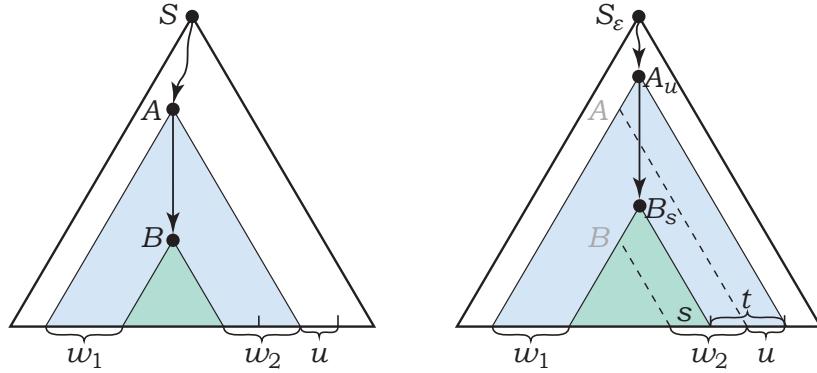


Рис. 3: Получение правила  $A_u \rightarrow w_1 B_s t$  в  $G'$  из правила  $A \rightarrow w_1 B w_2$  в  $G$

Пусть  $s$  обозначает первые  $k - 1$  символов строки  $w_2u$ , а  $t$  — оставшийся суффикс  $w_2u$ , так что  $s = \text{First}_{k-1}(w_2u)$  и  $st = w_2u$ .

Правило  $A_u \rightarrow \alpha$ , получается из правила  $A \rightarrow w_1 B w_2 \in R$  следующим образом: строка  $u$  дописывается в конец правила, так что получается правило  $A_u \rightarrow w_1 B w_2 u$ , а затем первые  $k - 1$  символов строки  $w_2u$  прикрепляются к нетерминалу  $B$  в качестве нижнего индекса.

$$A_u \rightarrow w_1 B_s t$$

Это проиллюстрировано на рисунке 3.

Для правил вида  $A \rightarrow x$ , где  $x \in \Sigma^*$ , соответствующие правила для нетерминалов  $A_u$  новой грамматики получаются просто приписыванием строки  $u$  в конец.

$$A_u \rightarrow xu$$

Заметим, что по каждому правилу  $A_u \rightarrow \alpha$  новой грамматики всегда можно однозначно восстановить правило  $A \rightarrow \gamma$  исходной грамматики, из которого оно получено: если  $\alpha \in \Sigma^*$ , то  $\gamma$  получается откусыванием у  $\alpha$  суффикса  $u$ , а если  $\alpha = w_1 B_s t$ , то  $\gamma$  получается откусыванием суффикса  $u$  строки  $w_1 B s t$ .

Доказательство корректности описанного построения естественно разбивается на несколько отдельных утверждений: а именно, что  $G'$  является линейной  $LL(k)$  грамматикой, задаёт тот же язык, что и  $G$ , и не содержит коротких правил.

Начнём с доказательства уже упомянутого факта:  $L_{G'}(A_u) = \{xu \mid x \in L_G(A)\}$ .

Как обычно, чтобы установить равенство множеств, проверим два включения.

**Утверждение 1.** Если строка  $w$  задаётся нетерминалом  $A_u$  в новой грамматике, то  $w = xu$ , где  $x$  задаётся нетерминалом  $A$  в исходной грамматике.

*Доказательство.* Индукция по высоте дерева разбора строки  $w$  из нетерминала  $A_u$ .

**Базовый случай.** Пусть  $A_u$  задаёт  $w$  по правилу  $A_u \rightarrow w$ .

По построению правило  $A_u \rightarrow w$  получено из некоторого правила  $A \rightarrow x$  исходной грамматики и имеет вид  $A_u \rightarrow xu$ .

Таким образом  $x \in L_G(A)$ .

**Индукционный переход.** Пусть  $A_u$  задаёт  $w$  по правилу  $A_u \rightarrow w_1B_st$ , полученному из правила  $A \rightarrow w_1Bw_2$  исходной грамматики, где  $w_2u = st$ .

Тогда  $w = w_1yt$ , где  $y \in L_{G'}(B_s)$ , и высота дерева разбора  $y$  из нетерминала  $B_s$  меньше, чем у дерева разбора  $w$ .

По индукционному предположению,  $y = zs$ , где  $z \in L_G(B)$ .

Таким образом получаем  $w = w_1zst = w_1zw_2u$ , и так как строка  $w_1zw_2$  задаётся нетерминалом  $A$  с помощью правила  $A \rightarrow w_1Bw_2$ , значит  $w \in L_G(A)u$ .

□

**Утверждение 2.** Если строка  $x$  задаётся нетерминалом  $A$  исходной грамматики, то в новой грамматике  $A_u$  задаёт  $xu$ .

*Доказательство.* Индукция по высоте дерева разбора строки  $x$  из  $A$ .

**Базовый случай.** Пусть  $A$  задаёт  $x$  по правилу  $A \rightarrow x$ .

По построению, в грамматике  $G'$  есть правило  $A_u \rightarrow xu$ , значит  $xu \in L_{G'}(A_u)$ .

**Индукционный переход.** Пусть  $A$  задаёт  $x$  по правилу  $A \rightarrow w_1Bw_2$ .

Тогда  $x = w_1yw_2$ , где  $y \in L_G(B)$ .

Положим  $s = \text{First}_{k-1}(w_2u)$ .

Высота дерева разбора  $y$  из  $B$  меньше, чем у дерева разбора  $x$ , значит по предположению индукции  $ys \in L_{G'}(B_s)$ .

Грамматика  $G'$  содержит правило  $A_u \rightarrow w_1B_st$ , полученное из правила  $A \rightarrow w_1Bw_2$  исходной грамматики, поэтому  $w_1yst \in L_{G'}(A_u)$ .

Так как  $w_1yst = w_1yw_2u = xu$ , то строка  $xu$  лежит в языке  $L_{G'}(A_u)$ .

□

Итак, из последних двух утверждений следует, что для каждого нетерминала  $A_u \in N'$  выполняется  $L_{G'}(A_u) = L_G(A)u$ . В частности  $L(G') = L_{G'}(S_\varepsilon) = L_G(S) = L(G)$ , то есть  $G'$  задаёт тот же язык, что и  $G$ .

Аналогичное равенство имеет место и для соответствующих правил.

**Утверждение 3.** Для любого правила  $A_u \rightarrow \alpha$ ,  $\alpha \in (\Sigma \cup N')^*$  новой грамматики, полученного из правила  $A \rightarrow \gamma$  исходной грамматики, выполняется  $L_{G'}(\alpha) = L_G(\gamma)u$ .

*Доказательство.* Пусть правило  $G'$  имеет вид  $A_u \rightarrow w_1 B_s t$  и получено из правила  $A \rightarrow w_1 B w_2$  исходной грамматики  $G$ .

По построению,  $st = w_2 u$ , и по предыдущим двум утверждениям  $L_{G'}(B_s) = L_G(B)s$ .

Таким образом,  $L_{G'}(w_1 B_s t) = w_1 L_G(B)st = L_G(w_1 B w_2)u$ .

Если же правило  $G'$  имеет вид  $A_u \rightarrow xu$ , то оно получено из правила  $A \rightarrow x$ , и утверждение тривиально.

□

Теперь докажем, что в  $G'$  нет коротких правил.

Уже известно, что  $L_{G'}(A_u) = L_G(A)u$ , поэтому, если  $|u| = k - 1$ , то  $A_u$  не задаёт строк длины менее  $k - 1$ , и, следовательно, для таких нетерминалов коротких правил нет.

Чтобы показать, что нет коротких правил и для нетерминалов  $A_u \in N'$  с  $|u| < k - 1$ , потребуется разобраться, как устроены множества  $\text{Follow}(A_u)$ .

Для начала докажем ещё пару несложных вспомогательных утверждений.

**Утверждение 4.** Для любого правила  $A_u \rightarrow w_1 B_s t$  в  $G'$  верно

- $|s| \geq |u|$
- Если  $|t| > 0$ , то  $|s| = k - 1$ .

*Доказательство.* По построению правило  $A_u \rightarrow w_1 B_s t$  было получено из некоторого правила  $A \rightarrow w_1 B w_2$ , причём  $s = \text{First}_{k-1}(w_2 u)$  и  $st = w_2 u$ .

Поскольку  $|u| \leq k - 1$ , то  $|u| = |\text{First}_{k-1}(u)| \leq |\text{First}_{k-1}(w_2 u)| = |s|$ , и тем самым первая часть доказана.

Если  $|t| > 0$ , то,  $|\text{First}_{k-1}(w_2 u)| < |w_2 u|$ , и значит  $|s| = |\text{First}_{k-1}(w_2 u)| = k - 1$ .

□

**Утверждение 5.** Пусть  $A \in N$ ,  $v \in \text{Follow}(A)$ ,  $u$  в грамматике есть правило  $A \rightarrow w_1 B w_2$ . Тогда  $w_2 v \in \text{Follow}(B)$ .

*Доказательство.* По определению  $\text{Follow}(A)$ , существует некоторое дерево разбора с поддеревом  $A$ , за которым следует строка  $v$ . Обозначим это поддерево как  $T_A$ .

Пусть  $x$  — любая строка из  $L_G(B)$ . Тогда  $A$  задаёт  $w_1xw_2$  по правилу  $A \rightarrow w_1Bw_2$ . Если вставить на место  $T_A$  соответствующее дерево вывода  $w_1xw_2$  из  $A$ , получится дерево разбора с поддеревом  $B$ , за которым следует строка  $w_2v$ . Тогда по определению  $w_2v \in \text{Follow}(B)$ .

□

Следующее утверждение проливает свет на устройство множеств  $\text{Follow}(A_u)$ .

**Утверждение 6.** Для каждого нетерминала  $B_s \in N'$ , если  $y \in \text{Follow}(B_s)$ , то  $sy \in \text{Follow}(B)$ . Кроме того, если  $|s| < k - 1$ , то  $y = \varepsilon$ .

*Доказательство.* Пусть  $y \in \text{Follow}(B_s)$ . По определению существует поддерево  $B_s$  дерева разбора, за которым следует строка  $y$ .

Применим индукцию по глубине этого поддерева в дереве разбора.

**Базовый случай.** Пусть  $B_s$  является корнем всего дерева разбора, то есть  $B_s = S_\varepsilon$ . Так как правее всего дерева разбора листьев нет, то  $y = \varepsilon$  и значит  $sy = \varepsilon \in \text{Follow}(S)$ .

**Индукционный переход.** Пусть  $A_u$  — родитель  $B_s$  в дереве разбора.

К  $A_u$  применяется некоторое правило  $A_u \rightarrow w_1B_st$ , полученное из правила  $A \rightarrow w_1Bw_2$  исходной грамматики, где  $w_2u = st$ .

Обозначим за  $y'$  строку, которая следует за поддеревом  $A_u$ , так что  $y = ty'$  и  $y' \in \text{Follow}(A_u)$  (см. рисунок 3).

Так как глубина  $B_s$  строго больше глубины  $A_u$  в дереве разбора, то к  $A_u$  применимо индукционное предположение, и тем самым  $uy' \in \text{Follow}(A)$ .

По утверждению 5  $w_2uy' = sty' = sy \in \text{Follow}(B)$ , и первая часть утверждения 6 доказана.

Пусть теперь  $|s| < k - 1$ . По утверждению 4  $|s| \geq |u|$ , причём если  $|t| > 0$ , то  $|s| = k - 1$ .

Следовательно  $|u| < k - 1$  и  $t = \varepsilon$ . К  $A_u$  применимо индукционное предположение, и значит из  $|u| < k - 1$  следует  $y' = \varepsilon$ . Таким образом  $y = ty' = \varepsilon$ , и второе утверждение доказано.

□

По предыдущему утверждению для нетерминалов  $A_u$  с  $|u| < k - 1$  выполняется  $\text{Follow}(A_u) = \{\varepsilon\}$ , и тем самым в грамматике  $G'$  отсутствуют короткие правила.

Остается доказать, что  $G'$  является линейной LL( $k$ ) грамматикой. Линейность  $G'$  видна из построения.

**Утверждение 7.** Если  $G$  принадлежит классу LL( $k$ ), то  $G'$  — тоже.

*Доказательство.* Пусть  $A_u$  — нетерминал  $G'$  со следующими правилами.

$$\begin{aligned} A_u &\rightarrow \alpha_1 \\ A_u &\rightarrow \alpha_2 \\ &\vdots \\ A_u &\rightarrow \alpha_n \end{aligned}$$

По определению, грамматика  $G'$  обладает свойством LL( $k$ ) тогда и только тогда, когда для каждого нетерминала  $A_u$ , множества  $\text{First}_k(L(\alpha_j)\text{Follow}(A_u))$  попарно не пересекаются.

По построению, каждому правилу  $A_u \rightarrow \alpha_j$  однозначно соответствует правило  $A \rightarrow \gamma_j$  исходной грамматики  $G$ . Так  $G$  принадлежит классу LL( $k$ ), то множества  $\text{First}_k(L(\gamma_j)\text{Follow}(A))$  попарно не пересекаются.

Таким образом, чтобы доказать, что  $G'$  тоже принадлежит классу LL( $k$ ), достаточно показать, что  $\text{First}_k(L(\alpha_j)\text{Follow}(A_u)) \subseteq \text{First}_k(L(\gamma_j)\text{Follow}(A))$  для каждого правила  $\alpha_j$ .

По утверждению 3  $L_{G'}(\alpha_j) = L_G(\gamma_j)$  для каждого правила  $A_u \rightarrow \alpha_j$ , и по утверждению 6  $u\text{Follow}(A_u) \subseteq \text{Follow}(A)$ .

Следовательно,

$$\text{First}_k(L(\alpha_j)\text{Follow}(A_u)) = \text{First}_k(L(\gamma_j)u\text{Follow}(A_u)) \subseteq \text{First}_k(L(\gamma_j)\text{Follow}(A))$$

□

Таким образом грамматика  $G'$  принадлежит классу LL( $k$ ), что завершает доказательство корректности построения.

□

**Пример 2.** Применим описанное построение к грамматике из примера 1

$$\begin{aligned} S &\rightarrow aabSaa \\ S &\rightarrow a \quad (\text{короткое правило}) \end{aligned}$$

Получится следующая грамматика без коротких правил.

$$\begin{aligned} S_\varepsilon &\rightarrow aabS_a a \\ S_\varepsilon &\rightarrow a \\ S_a &\rightarrow aabS_a aa \\ S_a &\rightarrow aa \end{aligned}$$

Заметим, что  $\text{Follow}(S_\varepsilon) = \{\varepsilon\}$ , и поэтому правило  $S_\varepsilon \rightarrow a$  не короткое.

## 5 Приведение к виду LL(1)

После того, как из грамматики удалены все короткие правила, её можно преобразовать к виду LL(1) с помощью конструкции, кратко намеченной в начале.

Однако, перед этим удобно заранее избавиться от правил вида  $A \rightarrow B$ , чтобы избежать некоторых технических проблем.

**Лемма 2.** Для каждой линейной  $LL(k)$  грамматики  $G = (\Sigma, N, R, S)$  без коротких правил существует линейная  $LL(k)$  грамматика  $G' = (\Sigma, N, R', S)$  без коротких правил, задающая тот же язык и не содержащая правил вида  $A \rightarrow B$ . Количество нетерминалов  $G'$  такое же, как у грамматики  $G$ .

*Доказательство.* Правила вида  $A \rightarrow B$  естественным образом задают ориентированный граф на множестве  $N$ : в графе есть ребро из  $A$  в  $B$  тогда и только тогда, когда в  $G$  есть правило  $A \rightarrow B$ .

Обозначим  $c(A)$  за множество всех вершин, достижимых из нетерминала  $A$ .

Правила грамматики  $G'$  определяются следующим образом: Пусть  $R_A$  — множество правил грамматики  $G$  для нетерминала  $A$ , кроме правил вида  $A \rightarrow B$ .

Положим  $R'_A = \bigcup_{B \in c(A)} \{A \rightarrow \alpha \mid (B \rightarrow \alpha) \in R_B\}$ . Тогда  $R' = \bigcup_{A \in N} R'_A$ .

Чтобы доказать лемму, нужно проверить четыре утверждения.

1.  $L_{G'}(A) = L_G(A)$ .
2.  $G'$  не содержит коротких правил.
3.  $G'$  — линейная  $LL(k)$  грамматика.
4.  $G'$  не содержит правил вида  $A \rightarrow B$ .

Приведённое построение классическое, и хоть отсутствие коротких правил и сохранение свойства  $LL(k)$  и требуют некоторых пояснений, читатель, знакомый с ним, вряд ли найдёт здесь для себя что-то новое.

Покажем, что деревья разбора грамматик  $G$  и  $G'$  находятся в естественном взаимно однозначном соответствии.

Любое дерево разбора  $G$  представляет из себя путь по вершинам, помеченным нетерминалами, от которых влево и вправо отходят листья, как показано на рисунке 1(слева). Пусть  $A_1 \rightarrow A_2 \rightarrow A_3 \rightarrow \dots \rightarrow A_n$  — этот путь, и к  $A_n$  применяется правило  $A_n \rightarrow x$ , где  $x \in \Sigma^*$ .

Тогда соответствующая последовательность правил выглядит так:

$$\begin{aligned}
 A_1 &= A_{n_0} \rightarrow A_{n_0+1}, & A_{n_0+1} &\rightarrow A_{n_0+2}, & \cdots, & A_{n_1-1} &\rightarrow u_1 A_{n_1} v_1, \\
 A_{n_1} &\rightarrow A_{n_1+1}, & A_{n_1+1} &\rightarrow A_{n_1+2}, & \cdots, & A_{n_2-1} &\rightarrow u_2 A_{n_2} v_2, \\
 &\vdots \\
 A_{n_{k-1}} &\rightarrow A_{n_{k-1}+1}, & A_{n_{k-1}+1} &\rightarrow A_{n_{k-1}+2}, & \cdots, & A_{n_k-1} &= A_n \rightarrow x
 \end{aligned}$$

В грамматике  $G'$  каждая строчка сжимается в одно правило, чему соответствует последовательность правил

$$\begin{aligned}
 A_0 &= A_{n_0} \rightarrow u_1 A_{n_1} v_1, \\
 A_{n_1} &\rightarrow u_2 A_{n_2} v_2, \\
 &\vdots \\
 A_{n_{k-1}} &\rightarrow x
 \end{aligned}$$

Аналогично, по любому дереву разбора  $G'$  можно восстановить дерево разбора  $G$ . Пусть  $B_1 \rightarrow B_2 \rightarrow \dots \rightarrow B_m$  — путь из нетерминалов в дереве разбора  $G'$ . Соответствующий путь в дереве разбора  $G$  получается вставкой некоторых правил вида  $A \rightarrow B$ : пусть поддерево  $B_j$  задаёт строку  $x_j$ , и за этим поддеревом следует строка  $y_j$ . Тогда, чтобы получить путь в дереве разбора  $G$ , надо на место каждого правила  $B_j \rightarrow w_1 B_{j+1} w_2$  вставить цепочку правил  $B_j = B_{j_1} \rightarrow B_{j_2}, \dots, B_{j_{k-1}} \rightarrow B_{j_k} = B_{j+1}$ , где

$$\begin{aligned}
 T(B_{j_1}, \text{First}_k(x_j y_j)) &= B_{j_1} \rightarrow B_{j_2} \\
 &\vdots \\
 T(B_{j_{k-2}}, \text{First}_k(x_j y_j)) &= B_{j_{k-2}} \rightarrow B_{j_{k-1}} \\
 T(B_{j_{k-1}}, \text{First}_k(x_j y_j)) &= B_{j_{k-1}} \rightarrow w_1 B_{j_k} w_2
 \end{aligned}$$

Из описанного соответствия деревьев разбора сразу следует, что  $L_G(A) = L_{G'}(A)$  для каждого нетерминала  $A \in N$ . Также несложно заметить, что если строка  $y$  следует за нетерминалом  $A$  в грамматике  $G'$ , то в соответствующем дереве разбора  $y$  следует за  $A$  в грамматике  $G$ , и таким образом  $\text{Follow}(A)_{G'} \subseteq \text{Follow}(A)_G$ .

Значит, если в грамматике  $G'$  нетерминал  $A$  задаёт строку длины менее  $k - 1$ , и  $\text{Follow}(A)_{G'} \neq \{\varepsilon\}$ , то же самое происходит и в грамматике  $G$ . Поэтому из отсутствия в  $G$  коротких правил следует отсутствие коротких правил в  $G'$ .

Линейность  $G'$  и отсутствие в ней правил вида  $A \rightarrow B$  видны из построения, а  $\text{LL}(k)$  таблица для  $G'$  получается из  $\text{LL}(k)$  таблицы  $G$  следующим образом: пусть  $T_G(A_1, u) = A_1 \rightarrow A_2, T_G(A_2, u) = A_2 \rightarrow$

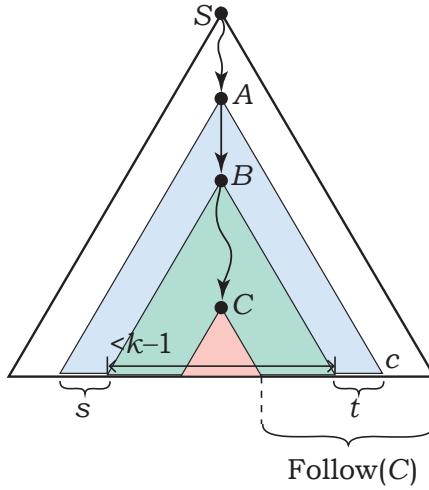


Рис. 4: Иллюстрация к доказательству утверждения 8.

$A_3, \dots, T_G(A_{k-1}, u) = A_{k-1} \rightarrow w_1 A_k w_2$ . Тогда  $T_{G'}(A_1, u) = w_1 A_k w_2$ . Если  $T_G(A_1, u)$  не определено, то не определено и  $T_{G'}(A_1, u)$ .

□

После того, как правила вида  $A \rightarrow B$  устраниены, у грамматики появляется хорошее свойство, которое нам потом понадобится.

**Утверждение 8.** Пусть  $G = (\Sigma, N, R, S)$  – линейная  $LL(k)$  грамматика без коротких правил и правил вида  $A \rightarrow B$ . Тогда для любого нетерминала  $A \in N$  если  $x \in L(A)$  и  $|x| = k - 1$ , то либо  $\text{Follow}(A) = \{\varepsilon\}$ , либо в  $R$  есть правило  $A \rightarrow x$ .

*Доказательство.* Пусть  $x \in L(A)$ ,  $\text{Follow}(A) \neq \{\varepsilon\}$  и  $A \rightarrow \alpha$  – правило, по которому  $A$  задаёт  $x$ . Пусть  $c \in \Sigma$  – любой символ из  $\text{First}_1(\text{Follow}(A))$ .

Тогда  $T(A, xc) = A \rightarrow \alpha$ . Если  $\alpha \in \Sigma^*$ , то  $\alpha = x$  и всё доказано.

Предположим,  $\alpha = sBt$  для некоторых  $s, t \in \Sigma^*$ . Тогда  $x = syt$ , где  $y \in L(B)$ . Так как в  $G$  нет правил вида  $A \rightarrow B$ , то  $|s| + |t| > 0$ , и значит  $|y| < |x| = k - 1$ .

Рассмотрим дерево разбора  $y$  из  $B$ . Последнее правило в нём имеет вид  $C \rightarrow z$ , где  $|z| \leq |y| < k - 1$ .

Так как  $\text{Follow}(A) \neq \varepsilon$ , то и  $\text{Follow}(B) \neq \varepsilon$ , и  $\text{Follow}(C) \neq \varepsilon$  (см. рисунок 4).

Значит правило  $C \rightarrow y'$  короткое, что противоречит отсутствию в  $G$  коротких правил.

□

Итак, наконец, пришла пора описать основное построение.

**Лемма 3.** Для каждой линейной  $LL(k)$  грамматики  $G = (\Sigma, N, R, S)$  без коротких правил и правил вида  $A \rightarrow B$  существует линейная  $LL(1)$  грамматика  $G'$ , задающая тот же язык. Количество нетерминалов  $G'$  не превосходит  $|\Sigma^{\leq k-1}| \cdot |N|$ .

*Доказательство.* Нетерминалы новой грамматики  $G' = (\Sigma, N', R', {}_\varepsilon S)$ , имеют вид  $_u A$ , где  $A \in N$  и  $u \in \Sigma^{\leq k-1}$ .

Левый нижний индекс  $u$  нетерминала  $_u A$  выполняет роль буфера, в котором хранится до  $k - 1$  последних символов, прочтённых синтаксическим анализатором.

Начальным символом  $G'$  является  ${}_\varepsilon S$ , что соответствует  $S$  с пустым буфером.

Грамматика  $G'$  будет определена таким образом, что  $L_{G'}(_u A) = \{w \mid uw \in L_G(A)\}$ .

До тех пор, пока буфер не заполнен, анализатор читает символы входной строки и заносит их в буфер. Когда в буфере накопится  $k - 1$  символов, на вершине стека анализатора будет некий нетерминал  $_u A$ , где  $u \in \Sigma^{k-1}$ . Стока  $u$  и следующий символ  $a$  входной строки, доступный анализатору напрямую, вместе образуют  $k$  символов, необходимые, чтобы определить нужное правило для нетерминала  $A$ . Это правило находится с помощью обращения к элементу  $T(A, ua)$  в  $LL(k)$  таблице грамматики  $G$ .

Итак,  $N' = \{_u A \mid A \in N \text{ и } u \in \Sigma^{\leq k-1}\}$ . Правила грамматики  $G'$  представляются объединением трёх множеств  $R_1, R_2$  и  $R_3$ .

Множество правил  $R_1$  реализуют заполнение буфера. Для каждого нетерминала  $_u A$  с  $|u| < k - 1$ , и для каждого символа  $a \in \Sigma$ , в  $G'$  есть правило, заносящее этот символ в буфер.

$$_u A \rightarrow a \ _u a A$$

Правила  $R_2$  используются, когда буфер уже заполнен, и синтаксический анализатор  $G'$  может понять, какое правило исходной грамматики следует применить. Для каждого  $_u A \in N'$  и  $a \in \Sigma$ , где  $|u| = k - 1$  и значение  $T(A, ua)$  определено, в  $G'$  есть правило, получающееся *откусыванием* строки  $u$  из правила  $(A \rightarrow \alpha) = T(A, ua)$ . Если  $\alpha \in \Sigma^*$ , тогда  $\alpha = us$ , где  $s \in \Sigma^*$ , и соответствующее правило в  $G'$  имеет вид

$$_u A \rightarrow s$$

Если  $\alpha$  содержит нетерминал в правой части, то есть  $\alpha = sBt$ , где  $s, t \in \Sigma^*$ ,  $B \in N$ , то одна из строк  $u$  и  $s$  является префиксом другой, и имеем два случая:

$$\begin{aligned} _u A \rightarrow s' {}_\varepsilon B t, & \quad \text{если } s = us', \ s' \in \Sigma^* \\ _u A \rightarrow v B t, & \quad \text{если } u = sv, \ v \in \Sigma^+ \end{aligned}$$

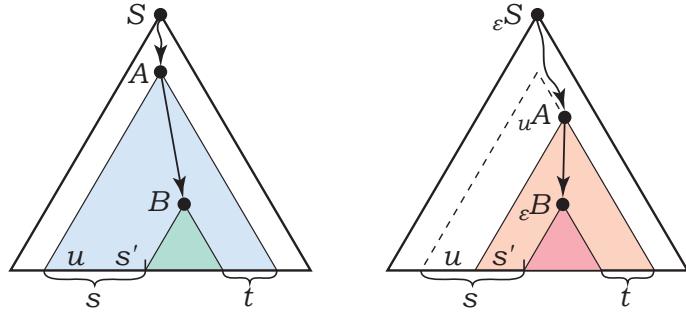


Рис. 5: Откусывание строки  $u$  из начала правила  $A \rightarrow sBt$  грамматики  $G$ : случай  $|u| \leq |s|$ .

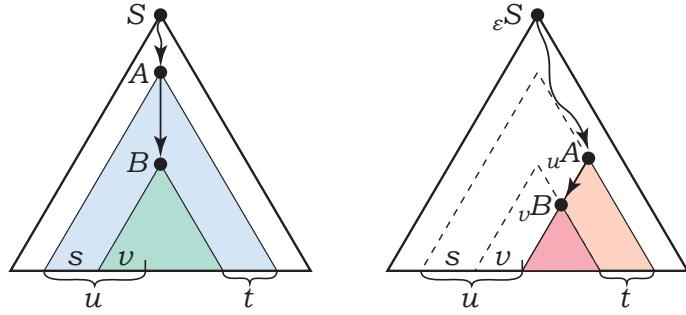


Рис. 6: Откусывание строки  $u$  из начала правила  $A \rightarrow sBt$  грамматики  $G$ : случай  $|u| > |s|$ .

Последние два правила показаны на рисунках 5 и 6. Наконец, правила  $R_3$  нужны для случая, когда вся строка уже прочитана анализатором, и ему нечего заносить в буфер. А именно, для каждого  $_uA \in N'$ , где  $|u| \leq k - 1$  и значение  $T(A, u)$  определено, грамматика  $G'$  содержит пустое правило.

$$_uA \rightarrow \varepsilon$$

Заметим, что  $R_1 \cap (R_2 \cup R_3) = \emptyset$ , однако множества  $R_2$  и  $R_3$  могут пересекаться по некоторым правилам вида  $_uA \rightarrow \varepsilon$ ,  $|u| = k - 1$ . Если известно, что правило  $_uA \rightarrow \alpha$  лежит в  $R_2$ , то всегда можно однозначно восстановить правило  $A \rightarrow \gamma$  исходной грамматики, из которого оно получено, исходя из определения откусывания  $u$ . Если  $\alpha \in \Sigma^*$ , то  $\gamma = u\alpha$ , если  $\alpha = s'_\varepsilon Bt$ , то  $\gamma = us'Bt$ , и, наконец, если  $\alpha = _vBt$ , то имеем  $u = sv$ , и  $\gamma = sBt$ .

Доказательство того, что  $G'$  обладает свойством  $LL(1)$  и задаёт тот же язык, что и  $G$ , даётся в серии утверждений.

Сначала установим заявленное равенство  $L_{G'}(_uA) = \{w \mid uw \in L_G(A)\}$ . Как обычно, докажем два включения.

**Утверждение 9.** Если  $x \in L_{G'}(uA)$ , то  $ux \in L_G(A)$ .

*Доказательство.* Доказательство проводится индукцией по высоте дерева разбора  $x$  из  $uA$ .

**Базовый случай:**  $x$  задаётся одним правилом  $uA \rightarrow x$ . Все правила  $R_1$  содержат нетерминал, поэтому  $uA \rightarrow x$  может быть либо из  $R_2$ , либо из  $R_3$ .

В первом случае  $uA \rightarrow x$ , получено из правила  $A \rightarrow ux$  в  $G$ . Тогда, очевидно,  $ux \in L_G(A)$ .

Во втором случае  $T(A, u)$  определено и  $x = \varepsilon$ . Так как  $T(A, u)$  определено и  $u < k$ , то  $u$  — суффикс входной строки.

Значит  $u = x't$ , где  $x' \in L_G(A)$  и  $t \in \text{Follow}(A)$ .

Если  $|x'| = k - 1$ , то, поскольку  $|u| \leq k - 1$ , то  $x' = u$ . Если же  $|x'| < k - 1$ , то из отсутствия в  $G$  коротких правил, следует, что  $t = \varepsilon$  и тем самым снова  $x' = x't = u$ .

Так или иначе, получаем  $ux = u = x' \in L_G(A)$

**Индукционный переход.** Пусть  $uA$  задаёт  $x$  по правилу  $uA \rightarrow \gamma$ , и  $\gamma$  содержит нетерминал.

Правило  $uA \rightarrow \gamma$  лежит либо в  $R_1$ , либо в  $R_2$ , соответственно имеем два случая.

Пусть  $uA \rightarrow \gamma$  лежит в  $R_2$  и получено откусыванием  $u$  из правила  $A \rightarrow sBt$  грамматики  $G$ . В соответствии с определением  $R_2$ , имеем два случая, в зависимости от того, какая из строк  $u$  и  $s$  длиннее.

- Если  $|u| > |s|$ , то  $\gamma = vBt$ , где  $u = sv$ . Тогда  $x = yt$  для некоторого  $y \in L_{G'}(vB)$ . Высота дерева разбора  $y$  из  $vB$  меньше высоты дерева разбора  $x$  из  $uA$ . Тогда, по предположению индукции,  $vy \in L_G(B)$ . Следовательно,  $ux = uyt = svyt \in L_G(sBt) \in L_G(A)$ .
- Если  $|u| \leq |s|$ , то  $\gamma = s'\varepsilon Bt$  где  $us' = s$ . Тогда  $x = s'yt$ , где  $y \in L_{G'}(\varepsilon B)$ .

По предположению индукции,  $y \in L_G(B)$ . Значит  $ux = us'yt = syt \in L_G(sBt) \in L_G(A)$ .

Пусть  $(uA \rightarrow \gamma) \in R_1$  — правило, наращивающее буфер.

Тогда  $\gamma = a_{ua}A$  для некоторого  $a \in \Sigma$ . Значит  $x = ay$ , где  $y \in L_{G'}(uaA)$ .

Следовательно, по предположению индукции,  $uay = ux \in L_G(A)$ .

□

Можно доказать похожее включение и для правил.

**Утверждение 10.** Пусть правило  $(_u A \rightarrow \gamma) \in R_2$  получено из правила  $A \rightarrow \alpha$ . Тогда, если  $x \in L_{G'}(\gamma)$ , то  $ux \in L_G(\alpha)$ .

*Доказательство.* Если  $\alpha \in \Sigma^*$ , то по построению  $\gamma = x$  и  $\alpha = ux$ . Пусть теперь  $\alpha = sBt$ , где  $s, t \in \Sigma^*$  и  $B \in N$ .

В соответствии с определением  $R_2$  имеем два случая.

Если  $|u| \leq |s|$ , то  $\gamma = s'_\varepsilon Bt$ , где  $us' = s$ . Тогда  $x = s'y t$ , где  $y \in L_{G'}(sB)$ . По утверждению 9  $y \in L_G(B)$ , и значит  $ux = us'y t = syt \in L_G(sBt)$ .

Если  $|u| > |s|$ , то  $\gamma = vBt$  где  $u = sv$ . Тогда  $x = yt$ , где  $y \in L_{G'}(vB)$ , и по утверждению 9  $vy \in L_G(B)$ . Значит  $ux = svyt \in L_G(sBt)$ .

□

**Утверждение 11.** Если  $ux \in L_G(A)$ , то  $x \in L_{G'}(_u A)$ .

*Доказательство.* Сначала разберём случай, когда  $|ux| < k$  и  $T(A, ux)$  определено. Тогда, по построению  $G'$  содержит правило  $_u A \rightarrow \varepsilon$ .

Пусть  $x = x_1 \dots x_m$ . Буфер  $u$  нетерминала  $_u A$  может быть расширен до  $ux$  с помощью следующих правил.

$$\begin{aligned} {}_u A &\rightarrow x_1 {}_{ux_1} A \\ {}_{ux_1} A &\rightarrow x_2 {}_{ux_1 x_2} A \\ {}_{ux_1 \dots x_{m-1}} A &\rightarrow x_m {}_{ux} A \end{aligned}$$

Эта последовательность в правил, вместе с правилом  $_u A \rightarrow \varepsilon$  составляют вывод  $x$  из  $_u A$ . Таким образом,  $x \in L_{G'}(_u A)$ .

Теперь предположим, что либо  $|ux| \geq k$ , либо  $|ux| = k - 1$ , но значение  $T(A, ux)$  не определено.

Если  $|ux| = k - 1$ , то из того, что  $T(A, ux)$  не определено, следует, что  $\text{Follow}(A) \neq \{\varepsilon\}$ , и поэтому существует некий символ  $c \in \text{Follow}_1(A)$ .

Положим  $n = k - |u| - 1$  и пусть  $a$  будет либо  $x_{n+1}$ , в случае  $|ux| \geq k$ , либо  $c$ , в случае  $|ux| = k - 1$ .

Обозначим за  $u'$  строку  $ux_1 \dots x_n$ .

Тогда  $|u'| = k - 1$  и  $T(A, u'a) = A \rightarrow \gamma$ , где  $A \rightarrow \gamma$  — правило, по которому  $A$  задаёт  $ux$ .

Буфер  $_u A$  может быть пополнен до  $u'$  с помощью следующих правил.

$$\begin{aligned} {}_u A &\rightarrow x_1 {}_{ux_1} A \\ {}_{ux_1} A &\rightarrow x_2 {}_{ux_1 x_2} A \\ {}_{ux_1 \dots x_{n-1}} A &\rightarrow x_n {}_{u'} A \end{aligned}$$

Тогда, так как  $T(A, u'a) = A \rightarrow \gamma$ , грамматика  $G'$  содержит правило  $u'A \rightarrow \alpha$ , где  $\alpha$  получается откусыванием  $u$  из  $\gamma$ .

Остаётся доказать, что  $\alpha$  задаёт строку  $x_{n+1} \dots x_m$ . Воспользуемся индукцией по высоте дерева разбора  $ux$  из  $A$ .

Заметим, что если  $\alpha$  задаёт строку  $x_{n+1} \dots x_m$ , то последовательность правил выше, вместе с правилом  $u'A \rightarrow \alpha$ , составляет вывод строки  $x_1 \dots x_m = x$  из  $_u A$ , и доказательство будет окончено. Поэтому можно считать, что предположением индукции служит всё доказываемое утверждение  $ux \in L_G(A) \Rightarrow x \in L_{G'}(_u A)$ .

**Базовый случай:**  $ux$  задаётся по правилу  $A \rightarrow ux$ . Тогда

$$\gamma = T(A, u'a) = A \rightarrow ux, \text{ и } \alpha = x_{n+1} \dots x_m.$$

**Индукционный переход:**  $ux$  задаётся по правилу  $A \rightarrow sBt$ .

Тогда  $ux = syt$ , где  $y \in L_G(B)$ , и  $\alpha$  получается откусыванием  $u'$  из строки  $sBt$ .

В соответствии с определением  $R_2$  имеем два случая, в зависимости от того, какая из строк  $u'$  и  $s$  длиннее.

Если  $|s| \geq |u'|$ , то  $\alpha = s'_\varepsilon Bt$ , где  $u's' = s$ .

Высота дерева разбора  $y$  из  $B$  меньше высоты дерева разбора  $ux$  из  $A$ . Тогда по предположению индукции  $y \in L_{G'}(\varepsilon B)$ .

Следовательно,  $u's'yt = syt = ux$ , и значит  $s'yt = x_{n+1} \dots x_m \in L_{G'}(\alpha)$ , что и требовалось доказать.

Если же  $|s| < |u'|$ , то  $\alpha = vBt$ , где  $sv = u'$ .

Чтобы воспользоваться предположением индукции для нетерминалов  $B$  и  $vB$  и строки  $y$ , необходимо показать, что  $v$  является префиксом  $y$ .

Так как в  $G$  нет коротких правил, то либо  $|y| \geq k - 1$ , либо  $t = \varepsilon$ .

Если  $t = \varepsilon$ , то  $ux = sy$ , и поскольку  $sv = u'$  является префиксом  $ux$ , то  $v$  является префиксом  $y$ .

Если же  $|y| = k - 1$ , то и  $|sy| \geq k - 1$ . Поскольку  $u'$  — это префикс  $ux = syt$ , и  $|u'| \leq k - 1$ , то строка  $u' = sv$  является префиксом  $sy$ , и следовательно  $v$  — префикс  $y$ .

Таким образом,  $y = vy'$  для некоторой строки  $y' \in \Sigma^*$ , и по предположению индукции  $y' \in L_{G'}(vB)$ .

Получаем  $u'y't = u'syt = ux$ , и значит  $y't = x_{n+1} \dots x_m \in L_{G'}(\alpha)$ , что и требовалось доказать.

□

Следующее утверждение устанавливает включение  $\text{Follow}(_u A) \subseteq \text{Follow}(A)$ .

**Утверждение 12.** Если  $y \in \text{Follow}(_u A)$ , то  $y \in \text{Follow}(A)$ .

*Доказательство.* По определению  $\text{Follow}(_u A)$  существует поддерево  $_u A$  некоторого дерева разбора, за которым следует строка  $y$ . Доказательство того, что  $y \in \text{Follow}(A)$  проводится индукцией по глубине поддерева.

**Базовый случай.** Пусть  $_u A$  является корнем всего дерева разбора, то есть  $_u A = {}_\varepsilon S$ .

В этом случае  $y = \varepsilon$ , поскольку справа от всего дерева разбора листьев нет. Таким образом,  $y = \varepsilon \in \text{Follow}(S)$ .

**Индукционный переход.** Пусть  $_v B$  — родитель  $_u A$  в дереве разбора, пусть  $_v B \rightarrow \gamma$  — соответствующее правило, и за поддеревом  $_v B$  следует строка  $y'$ .

Глубина поддерева с корнем  $_v B$  меньше глубины поддерева с корнем  $_u A$ , и так как  $y' \in \text{Follow}(_v B)$ , то по индукционному предположению  $y' \in \text{Follow}(B)$

Поскольку  $\gamma$  содержит нетерминал  $_u A$ , правило  $_v B \rightarrow \gamma$  лежит либо в  $R_1$ , либо в  $R_2$ .

В первом случае правило  $_v B \rightarrow \gamma$  наращивает буфер, и следовательно  $B = A$  и  $u = va$  для некоторого  $a \in \Sigma$ . Соответственно,  $_v B \rightarrow \gamma = _v A \rightarrow a {}_{va} A$ . Поэтому  $y' = y$ , и значит  $y \in \text{Follow}(A)$ .

Во втором случае  $\gamma$  получается откусыванием  $u$  из  $w_1 A w_2$ , где  $B \rightarrow w_1 A w_2$  — правило исходной грамматики. Поэтому  $y = w_2 y'$ . Так как  $y' \in \text{Follow}(B)$ , то по утверждению 5  $w_2 y' = y \in \text{Follow}(A)$ .

□

Грамматика  $G'$  линейна по построению и по утверждениям 9 и 11  $L(G') = L_{G'}({}_\varepsilon S) = L_G(S) = L(G)$ . Остаётся показать, что  $G'$  принадлежит классу  $LL(1)$ .

**Утверждение 13.** Грамматика  $G'$  принадлежит классу  $LL(1)$ .

Рассмотрим любые два правила  $_u A \rightarrow \gamma_1$  и  $_u A \rightarrow \gamma_2$  и покажем, если множества  $\text{First}_1(L(\gamma_1)\text{Follow}(_u A))$  и  $\text{First}_1(L(\gamma_2)\text{Follow}(_u A))$  пересекаются, то  $\gamma_1 = \gamma_2$ .

Доказательство проводится отдельно для случаев  $|u| < k - 1$  и  $|u| = k - 1$ . Пусть сначала  $|u| < k - 1$ .

Тогда каждое из правил  $_u A \rightarrow \gamma_1$  и  $_u A \rightarrow \gamma_2$  лежит в  $R_1$  или  $R_3$ . Разберём случаи.

- Если оба правила лежат в  $R_3$ , то  $\gamma_1 = \gamma_2 = \varepsilon$ .

- Если оба правила лежат в  $R_1$ , то  $\gamma_1 = a_{ua}A$  и  $\gamma_2 = b_{ub}A$  для некоторых символов  $a$  и  $b$ . Тогда  $\text{First}_1(L(\gamma_1)\text{Follow}_{(u}A)) = \{a\}$  и  $\text{First}_1(L(\gamma_2)\text{Follow}_{(u}A)) = \{b\}$ , и очевидно, что если последние множества пересекаются, то  $\gamma_1 = \gamma_2$
- Пусть одно из правил лежит в  $R_1$ , а другое — в  $R_3$ . Не умоляя общности,  $\gamma_1 = a_{ua}A$  для некоторого  $a \in \Sigma$ , а  $\gamma_2 = \varepsilon$ . Тогда  $\varepsilon \in L_{G'}(uA)$ , и  $u \in L_G(A)$  по утверждению 9. Поскольку в  $G$  нет коротких правил, и  $|u| < k-1$ , то  $\text{Follow}(A) = \{\varepsilon\}$ , а значит  $\text{Follow}_{(u}A) = \{\varepsilon\}$  по утверждению 12. Тогда  $\text{First}_1(L(\gamma_2)\text{Follow}_{(u}A)) = \{\varepsilon\}$ , и так как  $\text{First}_1(L(\gamma_1)\text{Follow}_{(u}A)) = \{a\}$ , то последние множества снова не пересекаются.

Пусть теперь  $|u| = k-1$ . Тогда, каждое из правил  $_uA \rightarrow \gamma_1$ ,  $_uA \rightarrow \gamma_2$  лежит в  $R_2$  или в  $R_3$ . Снова разберём случаи.

- Если оба правила лежат в  $R_3$ , то  $\gamma_1 = \gamma_2 = \varepsilon$ .
- Пусть, скажем,  $_uA \rightarrow \gamma_1$ , лежит в  $R_2$  и получено из правила  $A \rightarrow \alpha$ , а  $_uA \rightarrow \gamma_2$  лежит в  $R_3$ . Тогда  $\gamma_2 = \varepsilon$ , и значит, во-первых,  $u \in L_G(A)$ , и во-вторых,  $\text{First}_1(L_{G'}(\gamma_2)\text{Follow}_{(u}A)) = \text{First}_1(\text{Follow}_{(u}A))$ .

Предположим,  $\gamma_1$  задаёт пустую строку. Тогда  $\alpha$  задаёт  $u$  по утверждению 10. По определению  $R_2$  имеем  $(A \rightarrow \alpha) = T(A, ua)$  для некоторого  $a \in \Sigma$ , и поэтому  $\text{Follow}(A) \neq \{\varepsilon\}$ . Тогда  $\alpha = u$  по утверждению 8, и так как  $\gamma_1$  получается откусыванием  $u$  из  $\alpha$ , то  $\gamma_1 = \varepsilon = \gamma_2$ .

Пусть теперь  $\gamma_1$  не задаёт пустой строки, и тем самым  $\text{First}_1(L_{G'}(\gamma_1)\text{Follow}_{(u}A)) = \text{First}_1(L_{G'}(\gamma_1))$ .

То, что  $\varepsilon \notin \text{First}_1(L_{G'}(\gamma_1))$  уже предполагается. Пусть  $c \in \text{First}_1(L_{G'}(\gamma_1))$ , где  $c \in \Sigma$ . Тогда  $T(A, uc) = (A \rightarrow \alpha)$ .

Предположим, что  $c \in \text{First}_1(L_{G'}(\gamma_2)\text{Follow}_{(u}A)) = \text{First}_1(\text{Follow}_{(u}A))$ . Тогда из утверждения 12 следует, что  $c \in \text{First}_1(\text{Follow}(A))$ . Рассмотрим дерево разбора с поддеревом  $A$ , за которым следует строка, начинающаяся с символа  $c$ .

Так как  $u \in L_G(A)$ , то можно считать, что это поддерево задаёт строку  $u$ , как показано на рисунке 7.

Так как  $|u| = k-1$  и  $\text{Follow}(A) \neq \{\varepsilon\}$ , то из утверждения 8 следует, что  $A$  задаёт  $u$  по правилу  $A \rightarrow u$ .

Тогда по определению LL( $k$ )-таблицы имеем  $T(A, uc) = (A \rightarrow u)$ . Поэтому  $\alpha = u$ , и снова  $\gamma_1 = \varepsilon = \gamma_2$ .

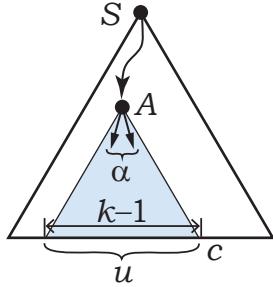


Рис. 7: Иллюстрация к доказательству того, что  $G'$  принадлежит классу  $\text{LL}(1)$

- Пусть теперь оба правила  $_u A \rightarrow \gamma_1$  и  $_u A \rightarrow \gamma_2$  лежат в  $R_2$  и получены из правил  $A \rightarrow \alpha_1$  и  $A \rightarrow \alpha_2$  соответственно.

Пусть  $x \in \text{First}_1(L(\gamma_1)\text{Follow}(_u A)) \cap \text{First}_1(L(\gamma_2)\text{Follow}(_u A))$ , где  $x \in \Sigma$  или  $x = \varepsilon$ .

Из утверждений [10] и [12] получаем  $ux \in \text{First}_k(L(\alpha_1)\text{Follow}(A)) \cap \text{First}_k(L(\alpha_2)\text{Follow}(A))$ .

Тогда, так как  $G$  принадлежит классу  $\text{LL}(k)$ , то  $\alpha_1 = \alpha_2$ , и значит снова имеем  $\gamma_1 = \gamma_2$ .  $\square$

Построения в утверждениях [1] и [3] приводят к увеличению количества нетерминалов в  $|\Sigma^{\leq k-1}|$  раз, а построение леммы [2] не меняет числа нетерминалов.

Таким образом, вместе упомянутые леммы влекут заявленный результат.

**Теорема 1.** Для каждой линейной  $\text{LL}(k)$  грамматики  $G = (\Sigma, N, R, S)$  существует линейная  $\text{LL}(1)$  грамматика с  $|N| \cdot |\Sigma^{\leq k-1}|^2$  нетерминальными символами, которая задаёт тот же язык.

## 6 Нижняя оценка

Ранее показывалось, как по линейной  $\text{LL}(k)$  грамматике  $G$  с множеством нетерминальных символов  $N$  построить линейную  $\text{LL}(1)$  грамматику с  $|N| \cdot |\Sigma^{\leq k-1}|^2$  нетерминальными символами, задающую тот же язык.

Покажем, что приведённое построение близко к оптимальному, и в худшем случае необходимо почти столько же нетерминальных символов.

**Теорема 2.** Для каждого натурального  $m \geq 3$ ,  $k \geq 4$  и  $n \geq 1$  существует язык над  $m$ -символьным алфавитом, задаваемый линейной  $\text{LL}(k)$  грамматикой  $G$  с  $n$  нетерминальными символами, такой что каждая линейная  $\text{LL}(1)$  грамматика, задающая тот же язык, имеет не менее  $n \cdot (m-1)^{2k-3-\lceil \log_{m-1} k \rceil}$  нетерминалов.

Линейная LL( $k$ ) грамматика  $G$ , задающая искомый язык будет определена над  $m$ -символьным алфавитом  $\Sigma \cup \{\#\}$ , где  $\#$  — специальный символ, не лежащий в  $\Sigma$ .

Грамматика будет содержать правила вида  $A \rightarrow xAf(x)$ , где  $x \in \Sigma^{k-1}\#$ , а  $f: \Sigma^{k-1}\# \rightarrow \Sigma$  — некоторая функция, которая будет определена позже, а также правила  $A \rightarrow \varepsilon$ .

Функция  $f$  будет устроена таким образом, чтобы любому синтаксическому анализатору для линейной LL(1) грамматики, задающей тот же язык, что и  $G$ , было необходимо хранить много информации в своём стеке.

Пусть  $1 \leq C \leq k - 1$  — фиксированная константа.

Рассмотрим момент, когда LL(1) анализатор прочёл первые  $k - C$  символов  $c_1 \dots c_{k-C}$  очередного блока  $x \in \Sigma^{k-1}\#$  входной строки, и до конца блока ему осталось прочесть ещё  $C$  символов  $d_{k-C+1} \dots d_{k-1}\#$ .

Чтобы определить значение  $f(x)$  после прочтения блока  $x$ , в указанный момент LL(1) анализатору необходимо помнить проекцию функции  $f$  на свои последние  $C$  аргументов  $d_{k-C+1} \dots d_{k-1}\#$ .

Обозначим последнюю проекцию за  $g$ , то есть  $g(d_{k-C+1} \dots d_{k-1}\#) = f(c_1 \dots c_{k-C}d_{k-C+1} \dots d_{k-1}\#)$ .

Постараемся выбрать функцию  $f$  и константу  $C$  так, чтобы количество возможных её возможных проекций  $g: \Sigma^{C-1}\# \rightarrow \Sigma$  было как можно большим.

**Лемма 4.** Для  $C = \lceil \log_{|\Sigma|} k \rceil + 1$  существует сюръективная функция  $f: \Sigma^{k-1}\# \rightarrow \Sigma$ , для которой все проекции  $g_s$ , получаемые подстановкой на место первых  $k - C$  аргументов  $f$  символов  $s$  (то есть  $g_s(t) = f(st)$ ), где  $s \in \Sigma^{k-C}$ , попарно различны.

*Доказательство.* Всего существует  $|\Sigma|^{\lfloor \Sigma \rfloor^{C-1}}$  возможных функций  $g: \Sigma^{C-1}\# \rightarrow \Sigma$ .

Чтобы различным строкам  $s \in \Sigma^{k-C}$  поставить в соответствие различные функции  $g_s$ , количество строк не должно превышать количество возможных функций.

$$|\Sigma|^{k-C} \leq |\Sigma|^{\lfloor \Sigma \rfloor^{C-1}}$$

Это неравенство выполняется, так как  $C = \lceil \log_{|\Sigma|} k \rceil + 1$  влечёт  $k - C \leq |\Sigma|^{C-1}$ .

Тогда строки  $s \in \Sigma^{k-C}$  возможно инъективно отобразить в функции  $g_s: \Sigma^{C-1}\# \rightarrow \Sigma$ , и искомая функция  $f$  определяется как  $f(st) = g_s(t)$ , для всех  $s \in \Sigma^{k-C}$  и  $t \in \Sigma^{C-1}\#$ .

Предположим, что построенная таким образом функция  $f$  не сюръективна, то есть существует множество символов  $\{a_1, \dots, a_r\} \subset \Sigma$ , где  $r \geq 1$ , такое что ни одна из строк  $\Sigma^{k-1}\#$  не отображается  $f$  ни в один из этих символов.

Рассмотрим прообраз  $f^{-1}(b)$  каждого символа  $b \in \Sigma$ . По крайней мере один прообраз  $f^{-1}(b)$  содержит не менее  $\frac{|\Sigma^{k-1}\#|}{|\Sigma|} > |\Sigma| > r$  строк.

Пусть  $x_1, \dots, x_r$  — любые  $r$  различных строк из  $f^{-1}(b)$ . Рассмотрим функцию  $f': \Sigma^{k-1}\# \rightarrow \Sigma$  определяемую следующим образом: если  $x \neq x_1, \dots, x_r$ , то  $f'(x) = f(x)$ , и  $f(x_j) = a_j$ .

Как несложно убедиться, функция  $f'$  сюръективна: для символов  $a \in \Sigma \setminus \{a_1, \dots, a_r, b\}$  имеем  $f'^{-1}(a) = f^{-1}(a) \neq \emptyset$ ,  $f'^{-1}(b) = f^{-1}(b) \setminus \{x_1, \dots, x_r\} \neq \emptyset$  и  $f'^{-1}(a_j) = x_j$ .

Покажем, что все проекции  $g'_s(t) = f'(st)$  попарно различны. Рассмотрим любые две различные строки  $s_1, s_2 \in \Sigma^{k-C}$ . По построению значения функций  $g_{s_1}$  и  $g_{s_2}$  различаются на некоторой строке  $t$  и, соответственно, имеем три случая:

1. Ни одна из строк  $s_1t$  и  $s_2t$  не совпадает с какой-то из  $x_1, \dots, x_r$ . Тогда  $g'_{s_1}(t) = f'(s_1t) = f(s_1t) = g_{s_1}(t)$  и  $g'_{s_2}(t) = f'(s_2t) = f(s_2t) = g_{s_2}(t)$ , значит  $g'_{s_1}(t) \neq g'_{s_2}(t)$ .
2. Только одна из строк  $s_1t, s_2t$ , скажем  $s_1t$ , совпадает с некоторой строкой  $x_j$ . Тогда  $f'(s_1t) = a_j$  и  $f'(s_2t) = f(s_2t)$ . Так как  $f(s_2t) \notin \{a_1, \dots, a_r\}$ , то  $f'(s_1t) \neq f'(s_2t)$  и значит  $g'_{s_1}(t) \neq g'_{s_2}(t)$ .
3. Пусть  $s_1t = x_i$  и  $s_2t = x_j$  для некоторых  $i, j \in \{1, \dots, r\}$ . Так как строки  $s_1t$  и  $s_2t$  различные, то  $x_i \neq x_j$ , и значит  $f'(s_1t) = a_i \neq a_j = f'(s_2t)$ .

□

Пусть далее  $f$  — некая фиксированная функция из леммы 4. Заявленная грамматика  $G = (\Sigma \cup \{\#\}, N, R, S)$  имеет множество нетерминалов  $N = \{A_1, \dots, A_n\}$ , где  $S = A_1$ .

Каждый нетерминал  $A_i$  ставит в соответствие блокам  $x \in \Sigma^{k-1}\#$  в начале строки символы  $f(x)$  в конце строки.

$$A_i \rightarrow x A_i f(x) \quad (1 \leq i \leq n, x \in \Sigma^{k-1}\#)$$

Внизу дерева разбора есть две возможности. Во-первых, нетерминал может задавать пустую строку.

$$A_i \rightarrow \varepsilon \quad (1 \leq i \leq n)$$

То, что блоки вида  $\Sigma^{k-1}\#$  закончились, LL(1) анализатор сможет понять лишь спустя  $k$  символов, когда в конце очередного предполагаемого блока не окажется символа  $\#$ . Во-вторых, может быть явно выписан номер нетерминального символа.

$$A_i \rightarrow b \#^i \quad (1 \leq i \leq n)$$

Последние правила нужны, чтобы нетерминалы LL(1) грамматики так или иначе хранили информацию о номере  $i$ . Наконец, номер нетерминального символа может быть изменён с помощью правила

$$A_i \rightarrow \#A_{i+1} \quad (1 \leq i < n)$$

Так определяется линейная LL( $k$ ) грамматика  $G$ , заявленная в Теореме 2.

Опишем её LL таблицу. Пусть  $A_i$  — нетерминал на вершине стека LL( $k$ ) анализатора.

- Если анализатор видит в начале непрочтёного суффикса строки  $\#$ , то он понимает, что должно быть применено правило  $A_i \rightarrow \#A_{i+1}$ , поэтому  $T(A_i, \#w) = (A_i \rightarrow \#A_{i+1})$  для всех строк  $w \in (\Sigma \cup \{\#\})^*$ , таких что  $\#w \in \text{First}_k(L_G(A_i)\text{Follow}(A_i))$  (для остальных  $w$  значения  $T(A_i, \#w)$  не определены).
- Если анализатор перед собой  $b\#$ , то он понимает, что должно быть применено правило  $A_i \rightarrow b\#^i$ , поэтому  $T(A_i, b\#^i w) = (A_i \rightarrow b\#^i)$  для всех строк  $w \in \Sigma^{k-i-1}$ .
- Если анализатор видит перед собой блок  $x \in \Sigma^{k-1}\#$ , то нужное правило —  $A_i \rightarrow xA_i f(x)$ , и поэтому  $T(A_i, x) = (A_i \rightarrow xA_i f(x))$  для всех  $x \in \Sigma^{k-1}\#$ .
- Наконец, если анализатор не видит впереди ни одного символа  $\#$ , то нужное правило  $A_i \rightarrow \varepsilon$ , и тем самым  $T(A_i, w) = (A_i \rightarrow \varepsilon)$  для всех  $w \in \Sigma^{k-1}$ .

Докажем, что каждая линейная LL(1) грамматика  $G' = (\Sigma \cup \{\#\}, N', R', S')$ , задающая тот же язык, что и  $G$ , должна иметь по крайней мере столько нетерминальных символов, сколько указано в теореме.

Доказательство использует следующие строки из языка  $L(G)$  (грамматика  $G$  порождает и другие строки).

$$\begin{aligned} \#^{i-1}x_1 \dots x_\ell f(x_\ell) \dots f(x_1), & \quad \text{где } i, \ell \geq 1, x_1, \dots, x_\ell \in \Sigma^{k-1}\# \\ \#^{i-1}x_1 \dots x_\ell b\#^i f(x_\ell) \dots f(x_1), & \quad \text{где } i, \ell \geq 1, x_1, \dots, x_\ell \in \Sigma^{k-1}\# \end{aligned}$$

Рассмотрим префикс строки указанного выше вида.

Пусть  $i \in \{1, \dots, n\}$ ,  $x_1, \dots, x_k \in \Sigma^{k-1}\#$ , и  $a_1, \dots, a_{k-C} \in \Sigma$ .

Положим

$$u = \#^{i-1}x_1 \dots x_k a_1 \dots a_{k-C}$$

Так как в строках из  $L(G)$  после префикса  $u$  может идти любой символ  $\Sigma$ , то после прочтения LL(1) анализатором для  $G'$  строки  $u$  содержимое его стека начинается с нетерминала, и значит имеет вид  $Av$ , где  $A \in N'$ , а  $v \in (\Sigma \cup \{\#\})^*$ .

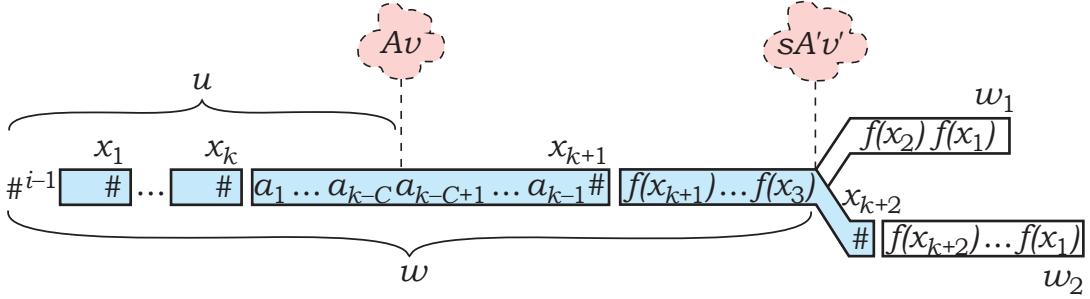


Рис. 8: Иллюстрация к доказательству леммы 5

Мы покажем, что для большого множества строк  $u$  указанного вида соответствующие нетерминалы  $A$  на вершине стека должны быть попарно различны.

Сперва покажем, что строка  $v$  короткая, и таким образом большая часть информации, находящейся в стеке анализатора, закодирована в нетерминале  $A$ .

**Лемма 5.** Пусть линейная  $LL(1)$  грамматика  $G' = (\Sigma \cup \{\#\}, N', R', S')$  задаёт язык  $L(G)$ , и пусть в стеке синтаксического анализатора для  $G'$  после прочтения строки вида  $u = \#^{i-1} x_1 \dots x_k a_1 \dots a_{k-C}$ , где  $i \in \{1, \dots, n\}$ ,  $x_1, \dots, x_k \in \Sigma^{k-1} \#$ , и  $a_1, \dots, a_{k-C} \in \Sigma$ , находится  $Av$ . Тогда  $|v| \leq 2$ .

*Доказательство.* Пусть  $a_{k-C+1}, \dots, a_{k-1} \in \Sigma$  любые символы. Рассмотрим следующие два блока из  $\Sigma^{k-1} \#$ .

$$\begin{aligned} x_{k+1} &= a_1 \dots a_{k-1} \# \\ x_{k+2} &= f(x_{k+1}) f(x_k) \dots f(x_3) \# \end{aligned}$$

Заметим, что начало  $x_{k+2}$  выглядит так, будто в исходной грамматике было применено правило  $A_i \rightarrow \varepsilon$ .

Рассмотрим следующие две строки, получающиеся дописыванием в конец  $u$  сначала, соответственно, одного блока  $x_{k+1}$  и двух блоков  $x_{k+1}$  и  $x_{k+2}$ , а затем — образов всех блоков под действием  $f$  (см. рисунок 8).

$$\begin{aligned} w_1 &= \#^{i-1} x_1 \dots x_k x_{k+1} f(x_{k+1}) f(x_k) \dots f(x_3) f(x_2) f(x_1) \\ w_2 &= \#^{i-1} x_1 \dots x_k x_{k+1} x_{k+2} f(x_{k+2}) f(x_{k+1}) f(x_k) \dots f(x_3) f(x_2) f(x_1) \end{aligned}$$

Обе строки начинаются с  $u$ , лежат в  $L(G)$  и имеют общий префикс

$$w = \#^{i-1} x_1 \dots x_k x_{k+1} f(x_{k+1}) f(x_k) \dots f(x_4) f(x_3)$$

Так как по крайней мере две строки из  $L(G)$ , а именно,  $w_1$  и  $w_2$ , начинаются с  $w$ , то в стеке  $LL(1)$  анализатора после прочтения  $w$  есть

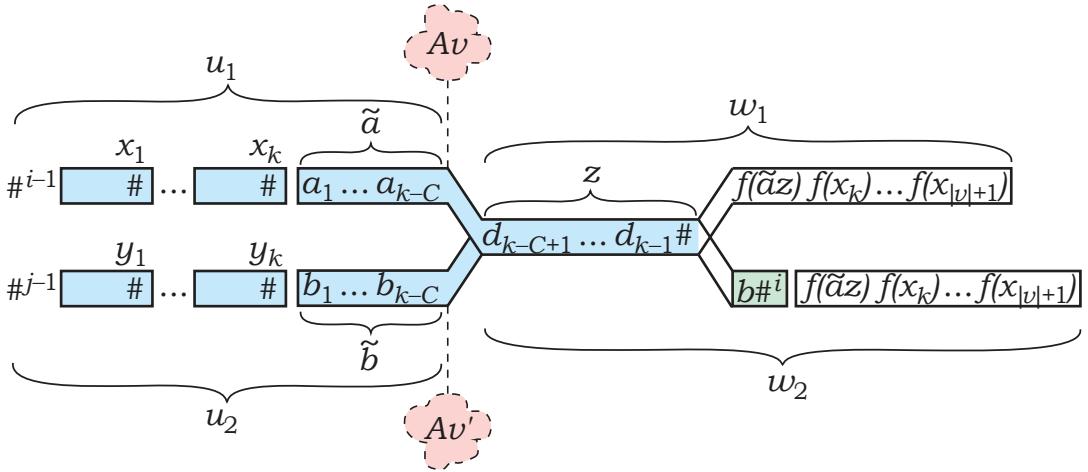


Рис. 9: Иллюстрация к доказательству леммы 6

нетерминал, то есть там лежит строка вида  $sA'v'$ , где  $v'$  заканчивается на  $v$ .

Тогда суффикс  $f(x_2)f(x_1)$  строки  $w_1$  должен представляться в виде  $syv'$ , где  $y \in L_{G'}(A')$ .

Значит  $|s| + |v'| \leq 2$ , и так как  $v$  — суффикс  $v'$ , то получаем  $|v| \leq 2$ .  $\square$

Рассмотрим теперь две различные строки того же вида, что и строка  $u$  из леммы 5.

Покажем, что если эти строки существенно различаются, то и нетерминалы, находящиеся на вершине стека анализатора после прочтения ими этих строк, должны быть различны.

**Лемма 6.** Пусть  $G' = (\Sigma \cup \{\#\}, N', R', S')$  — линейная LL(1) грамматика, задающая язык  $L(G)$ . Рассмотрим две строки следующего вида.

$$u_1 = \#^{i-1} x_1 \dots x_k a_1 \dots a_{k-C} \quad (A_i \in N, x_1, \dots, x_k \in \Sigma^{k-1}\#, a_1, \dots, a_{k-C} \in \Sigma)$$

$$u_2 = \#^{j-1} y_1 \dots y_k b_1 \dots b_{k-C} \quad (A_j \in N, y_1, \dots, y_k \in \Sigma^{k-1}\#, b_1, \dots, b_{k-C} \in \Sigma)$$

Пусть либо  $i \neq j$ , либо  $f(x_3) \dots f(x_k) \neq f(y_3) \dots f(y_k)$ , либо  $a_1 \dots a_{k-C} \neq b_1 \dots b_{k-C}$ , и после прочтения строк  $u_1$  и  $u_2$  на в стеке анализатора лежат строки  $Av$  и  $Bv'$  соответственно. Тогда  $A \neq B$ .

*Доказательство.* Предположим, что  $A = B$ , и значит после прочтения  $u_1$  и  $u_2$  в стеке лежит  $Av$  и  $Av'$  соответственно.

Положим  $\tilde{a} = a_1 \dots a_{k-C}$  и  $\tilde{b} = b_1 \dots b_{k-C}$  — последние незавершенные блоки строк  $u_1$  и  $u_2$ .

Если  $\tilde{a} \neq \tilde{b}$ , то по построению  $f$  блоки  $\tilde{a}$  и  $\tilde{b}$  можно продолжить некоторой строкой  $z = d_{k-C+1} \dots d_{k-1} \#$  длины  $C$ , где  $d_{k-C+1}, \dots, d_{k-1} \in \Sigma$ , так что  $f(\tilde{a}z) \neq f(\tilde{b}z)$ .

Если же  $\tilde{a} = \tilde{b}$ , то продолжим блоки  $\tilde{a}$  и  $\tilde{b}$  любой строкой  $z = d_{k-C+1} \dots d_{k-1} \#$ , где  $d_{k-C+1}, \dots, d_{k-1} \in \Sigma$ .

Рассмотрим следующие две строки из  $L(G)$ .

$$\begin{aligned} u_1 z f(\tilde{a}z) f(x_k) \dots f(x_1) \\ u_1 z b \#^i f(\tilde{a}z) f(x_k) \dots f(x_1) \end{aligned}$$

Так как после прочтения анализатором их общего префикса  $u_1$ , в стеке лежит  $Av$ , то оба оставшихся суффикса должны лежать в  $L_{G'}(Av)$  (см. рисунок 9).

Тогда префиксы этих суффиксов, содержащие все символы, кроме последних  $|v|$ , лежат в  $L_{G'}(A)$ . Обозначим последние строки за  $w_1$  и  $w_2$  соответственно.

$$\begin{aligned} w_1 &= z f(\tilde{a}z) f(x_k) \dots f(x_{|v|+1}) \\ w_2 &= z b \#^i f(\tilde{a}z) f(x_k) \dots f(x_{|v|+1}) \end{aligned}$$

(заметим, что  $|v| \leq 2$  по лемме 5).

По условию леммы,  $w_1$  и  $w_2$  должны различаться либо в количестве знаков  $\#$  в начале ( $i \neq j$ ), либо в каком-то из образов последних  $k - 2$  завершенных блоков ( $f(x_3) \dots f(x_k) \neq f(y_3) \dots f(y_k)$ ), либо в каком-то из символов последнего незавершенного блока ( $\tilde{a} \neq b$ ). Соответственно, нужно рассмотреть три случая.

- Пусть  $i \neq j$ . Так как в стеке анализатора после прочтения им  $w_2$  лежит строка  $Av'$ , то строка  $w_2 v'$  должна принадлежать языку  $L(G)$ .

$$w_2 v' = \#^{j-1} y_1 \dots y_k \tilde{b} z b \#^i f(\tilde{a}z) f(x_k) \dots f(x_{|v|+1}) v'$$

Предполагаемое дерево разбора  $w_2 v'$  несложно восстановить, пользуясь LL( $k$ ) таблицей  $G$ : сначала применяется  $j - 1$  правил  $A_1 \rightarrow \# A_2, \dots, A_{j-1} \rightarrow \# A_j$ , увеличивающих номер нетерминала, затем  $k + 1$  правил  $A_j \rightarrow y_1 A_j f(y_1), \dots, A_j \rightarrow y_k A_j f(y_k)$ ,  $A_j \rightarrow \tilde{b} z A_j f(\tilde{b}z)$ , сопоставляющих блокам  $y_1, \dots, y_k, \tilde{b}z \in \Sigma^{k-1} \#$  символы  $f(y_1), \dots, f(y_k), f(\tilde{b}z)$ , и, наконец, правило  $A_j \rightarrow b \#^j$ .

Таким образом должно выполняться  $i = j$ , что противоречит сделанному предположению.

- В случае, когда  $f(x_3) \dots f(x_k) \neq f(y_3) \dots f(y_k)$ , аналогично предыдущему получаем, что строка  $w_2 v'$  лежит в  $L(G)$ .

$$w_2 v' = \#^{j-1} y_1 \dots y_k b_1 \dots b_{k-C} z f(\tilde{a}z) f(x_k) \dots f(x_{|v|+1}) v'$$

Как и в предыдущем случае, можно явно рассмотреть предполагаемое дерево разбора  $w_2 v'$  и прийти к противоречию с тем, что  $f(x_3) \dots f(x_k) \neq f(y_3) \dots f(y_k)$ ,

- Пусть  $\tilde{a} \neq \tilde{b}$ . Тогда с одной стороны, как и в предыдущем случае, строка  $u_2w_1v'$  лежит в  $L(G)$ , но с другой стороны по выбору  $z$  имеем  $f(\tilde{a}z) \neq f(\tilde{b}z)$ , и можно снова рассмотреть предполагаемое дерево разбора  $u_2w_1v'$  и прийти к противоречию.

□

**Теоремы 2** Пусть  $i \in \{1, \dots, n\}$ ,  $d_3, \dots, d_k \in \Sigma$ ,  $a_1, \dots, a_{k-C} \in \Sigma$ . Так как  $f$  сюръективна, существуют строки  $x_1, \dots, x_k \in \Sigma^{k-1}\#$ , такие что  $f(x_j) = d_j$  для всех  $j \in \{3, \dots, n\}$ .

Определим строки  $u_{i;d_3, \dots, d_k; a_1, \dots, a_{k-C}}$  следующим образом.

$$u_{i;d_3, \dots, d_k; a_1, \dots, a_{k-C}} = \#^{i-1}x_1 \dots x_k a_1 \dots a_{k-C}$$

По лемме 6, после прочтения LL(1) анализатором различных строк указанного вида, на вершине его стека должны находиться различные нетерминальные символы.

Следовательно, в грамматике  $G'$  должно быть не меньше нетерминалов, чем существует различных строк  $u_{i;d_3, \dots, d_k; a_1, \dots, a_{k-C}}$ , то есть  $|N'| \geq n \cdot (m-1)^{2k-C-2}$ , как и заявлено.

□

## 7 Конъюнктивные линейные LL( $k$ ) грамматики

Языки, задаваемые нетерминалами формальной грамматики, можно определять как решения некоторых языковых уравнений.

Так, каждое правило  $A \rightarrow uBv$  означает, что  $L(A) \supseteq L(uBv)$ , и если  $A \rightarrow u_1B_1v_1, \dots, A \rightarrow u_kB_kv_k$  — все правила для нетерминала  $A$ , то язык, задаваемый  $A$ , определяется как  $L(A) = L(u_1B_1v_1) \cup \dots \cup L(u_kB_kv_k)$ .

Переменными в таких уравнениях являются языки, соответствующие нетерминалам грамматики, а также константные языки  $\{s\}$ ,  $s \in \Sigma^*$ , а допустимыми операциями — конкатенация и объединение.

Конъюнктивные грамматики обобщают обычные грамматики путём добавления операции *пересечения*. Правила конъюнктивной грамматики имеют вид  $A \rightarrow u_1B_1v_1 \& \dots \& u_kB_kv_k$  и означают, что  $L(A) \supseteq L(u_1B_1v_1) \cap \dots \cap L(u_kB_kv_k)$ . Как и прежде, если  $A \rightarrow \gamma_1, \dots, A \rightarrow \gamma_k$  — все правила для нетерминала  $A$ , то язык, задаваемый  $A$ , определяется как  $L(A) = L(\gamma_1) \cup \dots \cup L(\gamma_k)$ .

Дадим формальное определение.

**Определение 8.** *Конъюнктивной линейной (формальной) грамматикой называется четвёрка  $G = (\Sigma, N, R, S)$ , состоящая из следующих компонентов:*

1.  $\Sigma$  — конечное множество символов, называемое *алфавитом*.

2.  $N$  — конечное множество **нетерминалов**. Каждый нетерминал обозначает некоторое свойство, которым строка из  $\Sigma^*$  может обладать или не обладать.
3.  $R$  — конечное множество **правил грамматики**, каждое из которых описывает возможную структуру строк со свойством  $A \in N$ . Каждое правило имеет вид  $A \rightarrow u_1B_1v_1 \& u_2B_2v_2 \& \dots \& u_rB_rv_r$ , где  $B_1, \dots, B_r \in N$  — нетерминалы, а  $u_1, v_1, \dots, u_r, v_r \in \Sigma^*$  — строки или вид  $A \rightarrow x$ , где  $x \in \Sigma^*$ . Строки вида  $uBv$ , входящие в правила, называются **конъюнктами**.  
Наличие правила  $A \rightarrow u_1B_1v_1 \& u_2B_2v_2 \& \dots \& u_rB_rv_r$  означает, что если строку  $w$  можно представить в виде конкатенации  $w = u_i s_i v_i$ , где  $s_i$  обладает свойством  $B_i$ , для каждого  $i = 1, \dots, r$ , то строка  $w$  обладает свойством  $A$ . Правила вида  $A \rightarrow x$ , где  $x \in \Sigma^*$ , как и стоит ожидать, означают, что  $x$  обладает свойством  $A$ .
4.  $S \in N$  — выделенный **начальный нетерминал**.

Столь же важным, сколь и в неконъюнктивном случае, является понятие *дерева разбора*. Стоит заметить, что деревья разбора конъюнктивной грамматики получаются склеиванием некоторых листьев упорядоченного корневого дерева, и тем самым представляют из себя графы, в строгом смысле деревьями не являющиеся. Однако мы всё равно будем называть их деревьями, их самые нижние вершины — листьями, а также использовать и другую «древесную» терминологию.

**Определение 9.** Деревья разбора конъюнктивной грамматики проще всего определить индуктивно. Каждому правилу вида  $A \rightarrow w$ ,  $w \in \Sigma^*$  соответствует дерево разбора  $w$  из  $A$  высоты 1, такое же, как и в неконъюнктивном случае: вершина, помеченная  $A$ , является корнем, и от неё отходят листья, образующие строку  $w$ .

Пусть теперь в  $G$  есть правило  $A \rightarrow u_1B_1v_1 \& \dots \& u_rB_rv_r$ , нетерминалы  $B_1, \dots, B_r$  задают строки  $s_1, \dots, s_r$ , и соответствующие деревья разбора имеют высоту не более  $n - 1$ , причём  $u_1s_1v_1 = \dots = u_rs_rv_r = w$ . Тогда будем говорить, что  $A$  задаёт  $w$  по правилу  $A \rightarrow u_1B_1v_1 \& \dots \& u_kB_kv_k$ , и соответствующее дерево разбора имеет высоту  $n$  и получается из деревьев разбора  $s_j$  из  $B_j$  следующим образом.

1. Каждому дереву разбора  $s_j$  из  $B_j$  ставится в соответствие «дерево разбора»  $w$  из  $A$  по «правилу»  $A \rightarrow u_jB_jv_j$ , как показано на рисунке 10. Заметим, что правила  $A \rightarrow u_jB_jv_j$  в грамматике нет, поэтому данное дерево разбора сугубо промежуточное и не является корректным деревом разбора  $w$  из  $A$ .

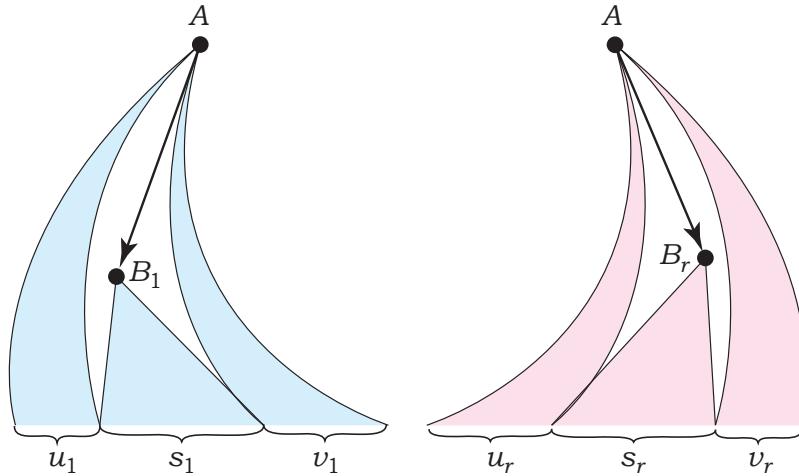


Рис. 10: Промежуточные деревья разбора

2. Корни и листья всех этих деревьев склеиваются, как показано на рисунке 11. Таким образом получается, что,  $A$  задаёт  $w$  по всем конъюнктам  $u_j B_j v_j$  сразу.

Язык задаваемый нетерминалом  $A$  обозначается  $L(A)$  и определяется как множество всех строк  $w$ , задаваемых  $A$  за некоторое число шагов. Соответствующие деревья разбора называются деревьями разбора  $w$  из  $A$ .

Язык задаваемый грамматикой обозначается  $L_G$  и определяется как язык, задаваемый её начальным нетерминалом  $S$ .

Язык, задаваемый конъюнкцией  $\varphi = \alpha_1 \& \dots \& \alpha_r$ , определяется как  $L(\varphi) = L(\alpha_1) \cap \dots \cap L(\alpha_r)$ .

**Определение 10.** Пусть  $G = (\Sigma, N, R, S)$  — конъюнктивная формальная грамматика.

Пусть зафиксировано некоторое дерево разбора  $G$  и поддерево в нём.

Будем говорить, что строка  $u \in \Sigma^*$  **следует** за этим поддеревом, если все листья справа от поддерева образуют строку  $u$ , как на рисунке 11 (в середине).

Так же, как и в неконъюнктивном случае, определяется класс  $LL(k)$ .

**Определение 11.**  $LL(k)$ -таблицей для конъюнктивной грамматики  $G = (\Sigma, N, R, S)$  называется частично определённая функция  $T : N \times \Sigma^{\leq k} \rightarrow R$ , удовлетворяющая следующему условию.  $T(A, x) = (A \rightarrow \alpha)$ , где  $A \in N, x \in \Sigma^{\leq k}$ , тогда и только тогда, когда существует поддерево некоторого дерева разбора, помеченное нетерминалом  $A$ , такое что первые  $k$  листьев всего дерева, начиная с самого левого листа поддерева,

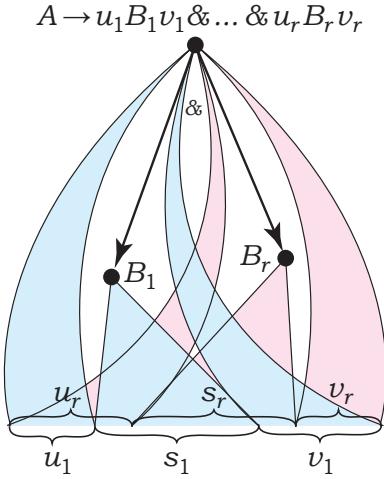


Рис. 11: Дерево разбора  $w$  из  $A$

образуют строку  $x$ , и к корню поддерева применяется правило  $A \rightarrow \alpha$ , как показано на рисунке 11(справа).

Если для грамматики  $G$  существует  $LL(k)$ -таблица, то говорят, что  $G$  принадлежит классу  $LL(k)$ .

Известно, что выразительные способности конъюнктивных  $LL$ -линейных грамматик сильно ограничены: как установлено Охотиным [], они не могут задать никакой язык вида  $L \cdot \{a, b\}$ , где  $L$  — нерегулярный. Поэтому следующий пример нетривиального языка, задаваемого такими грамматиками, представляется небезынтересным.

**Пример 3.** Пусть  $\Sigma = \{a, b, c, \#\}$ , и пусть  $h: \Sigma^* \rightarrow \{a, b\}^*$  — гомоморфизм, задаваемый соотношениями  $h(a) = aa$ ,  $h(\#) = ab$ ,  $h(c) = ba$ ,  $h(b) = bb$ . Тогда следующая конъюнктивная  $LL(1)$ -линейная грамматика задаёт язык, состоящий из всех строк  $w_i$ , где  $w_0 = c$ ,  $w_{i+1} = h(w_i^R)\#w_i$ .

$$\begin{aligned} S &\rightarrow X \& R \mid c \\ X &\rightarrow h(s)Xs \quad (s \in \Sigma) \\ X &\rightarrow \# \\ R &\rightarrow aR \mid bR \mid \#S \end{aligned}$$

Следующий результат данной работы заключается в том, что для конъюнктивных грамматик верен аналог теоремы 1.

**Теорема 3.** Для каждой конъюнктивной линейной  $LL(k)$  грамматики  $G = (\Sigma, N, R, S)$  существует конъюнктивная линейная  $LL(1)$  грамматика, которая задаёт тот же язык.

Доказательство последней теоремы почти дословно повторяет аналогичное доказательство для неконъюнктивного случая, и поэтому некоторые детали будут опускаться. Читатель без труда сможет их восстановить, обратившись к соответствующим местам доказательства теоремы [II](#).

Сперва из грамматики  $G$  удаляются «короткие правила», затем удаляются правила вида  $A \rightarrow B$  и, наконец, грамматика приводится к виду LL(1) с помощью прикрепления к каждому нетерминалу специального буфера.

Стоит заметить, что для конъюнктивных грамматик не верен аналог факта [I](#), поэтому принадлежность классу LL( $k$ ) будет проверяться напрямую по определению, без использования множеств First $_k(A)$  и Follow( $A$ ) нетерминалов  $A \in N$ .

## 8 Конъюнктивные грамматики: устранение «коротких» правил

**Определение 12.** *Коротким правилом будем называть правило вида  $A \rightarrow w$ , такое что  $w \in \Sigma^*$ ,  $|w| < k - 1$  и существует дерево разбора с поддеревом  $A$ , за которым следует некая непустая строка, как показано на рисунке [2](#) (справа).*

**Лемма 7.** *Для каждой конъюнктивной линейной LL( $k$ ) грамматики  $G = (\Sigma, N, R, S)$  существует конъюнктивная линейная LL( $k$ ) грамматика  $G'$  без коротких правил, задающая тот же язык.*

*Доказательство.* Как и в лемме [I](#), нетерминалы грамматики  $G' = (\Sigma, N', R', S_\varepsilon)$  имеют вид  $A_u$ , где  $A \in N$  и  $u \in \Sigma^{\leq k-1}$ .

Для каждого нетерминала  $A_u$  и для каждого правила  $A \rightarrow \gamma_1 \& \dots \& \gamma_r \in R$ , в новой грамматике будет правило  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_r$ , где каждый конъюнкт  $\alpha_j$  получается из конъюнкта  $\gamma_j$  следующим образом.

Пусть  $\gamma_j = w_1 B w_2$ . Обозначим за  $s$  первые  $k - 1$  символов строки  $w_2 u$ , а за  $t$  — оставшийся суффикс  $w_2 u$ , так что  $s = \text{First}_{k-1}(w_2 u)$  и  $st = w_2 u$ . Тогда положим  $\alpha_j = w_1 B s t$ .

Для правил вида  $A \rightarrow x$ , где  $x \in \Sigma^*$ , соответствующие правила для нетерминалов  $A_u$  новой грамматики получаются просто приписыванием строки  $u$  в конец.

$$A_u \rightarrow xu$$

Заметим, что по каждому правилу  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_k$  новой грамматики всегда можно однозначно восстановить правило  $A \rightarrow \gamma_1 \& \dots \& \gamma_k$  исходной грамматики, из которого оно получено: если  $\alpha_j \in \Sigma^*$ , то  $\gamma_j$

получается откусыванием у  $\alpha_j$  суффикса  $u$ , а если  $\alpha_j = w_1 B_s t$ , то  $\gamma_j$  получается откусыванием суффикса  $u$  у строки  $w_1 B_s t$ .

Доказательство корректности описанного построения естественно разбивается на несколько отдельных утверждений: а именно, что  $G'$  является конъюнктивной линейной  $LL(k)$  грамматикой, задаёт тот же язык, что и  $G$ , и не содержит коротких правил.

Сначала докажем, что  $L_{G'}(A_u) = \{xu \mid x \in L_G(A)\}$ .

**Утверждение 14.** *Если строка  $w$  задаётся нетерминалом  $A_u$  в новой грамматике, то  $w = xu$ , где  $x$  задаётся нетерминалом  $A$  в исходной грамматике.*

*Доказательство.* Индукция по высоте дерева разбора строки  $w$  из нетерминала  $A_u$ .

**Базовый случай.** Пусть  $A_u$  задаёт  $w$  по правилу  $A_u \rightarrow w$ .

По построению правило  $A_u \rightarrow w$  получено из некоторого правила  $A \rightarrow x$  исходной грамматики и имеет вид  $A_u \rightarrow xu$ .

Таким образом  $x \in L_G(A)$ .

**Индукционный переход.** Пусть  $A_u$  задаёт  $w$  по правилу  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_r$ , полученному из правила  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ .

Зафиксируем  $j \in \{1, \dots, r\}$ . Пусть  $\alpha_j = w_1 B_s t$ . Тогда  $\gamma_j = w_1 B w_2$ , где  $w_2 u = st$ .

Значит  $w = w_1 y t$ , где  $y \in L_{G'}(B_s)$ , и высота дерева разбора  $y$  из нетерминала  $B_s$  меньше, чем у дерева разбора  $w$  из  $A_u$ .

По индукционному предположению,  $y = zs$ , где  $z \in L_G(B)$ .

Таким образом получаем  $w = w_1 z s t = w_1 z w_2 u$ . Значит строка  $w$  имеет вид  $xu$ , где  $x = w_1 z w_2$  лежит в  $L_G(\gamma)$ . Так как  $j$  выбиралось произвольным, то  $x$  лежит в каждом из языков  $L_G(\gamma_1), \dots, L_G(\gamma_r)$ , и значит задаётся нетерминалом  $A$  с помощью правила  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ . В частности  $w \in L_G(A)u$ .

□

**Утверждение 15.** *Если строка  $x$  задаётся нетерминалом  $A$  исходной грамматики, то в новой грамматике  $A_u$  задаёт  $xu$ .*

*Доказательство.* Индукция по высоте дерева разбора строки  $x$  из  $A$ .

**Базовый случай.** Пусть  $A$  задаёт  $x$  по правилу  $A \rightarrow x$ .

По построению, в грамматике  $G'$  есть правило  $A_u \rightarrow xu$ , значит  $xu \in L_{G'}(A_u)$ .

**Индукционный переход.** Пусть  $A$  задаёт  $x$  по правилу  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ . Зафиксируем  $j \in \{1, \dots, r\}$ . Пусть  $\gamma_j = w_1 B w_2$ . Тогда  $x = w_1 y w_2$ , где  $y \in L_G(B)$ .

Положим  $s = \text{First}_k(w_2 u)$ .

Высота дерева разбора  $y$  из  $B$  меньше, чем у дерева разбора  $x$ , значит по предположению индукции  $ys \in L_{G'}(B_s)$ .

Грамматика  $G'$  содержит правило  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_r$ , где каждый конъюнкт  $\alpha_i$  получен из соответствующего конъюнкта  $\gamma_i$ , так что  $\alpha_j = w_1 B_s t$ , где  $st = w_2 u$ . Значит  $w_1 y st \in L_{G'}(\alpha_j)$ , и так как Так как  $w_1 y st = w_1 y w_2 u = xu$ , то строка  $xu$  лежит в языке  $L_{G'}(\alpha_j)$ .

Поскольку  $j$  выбиралось произвольно, то  $xu \in L_{G'}(\alpha_1) \cap \dots \cap L_{G'}(\alpha_r)$ , и тем самым  $A_u$  задаёт  $xu$  по правилу  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_r$ .

□

Итак, из последних двух утверждений следует, что для каждого нетерминала  $A_u \in N'$  выполняется  $L_{G'}(A_u) = L_G(A)u$ . В частности  $L(G') = L_{G'}(S_\varepsilon) = L_G(S) = L(G)$ , то есть  $G'$  задаёт тот же язык, что и  $G$ .

Аналогичное равенство имеет место и для соответствующих правил.

**Утверждение 16.** Для любого правила  $A_u \rightarrow \varphi$  новой грамматики, полученного из правила  $A \rightarrow \varphi'$  исходной грамматики, выполняется  $L_{G'}(\varphi) = L_G(\varphi')u$ .

*Доказательство.* Пусть  $\varphi = \alpha_1 \& \dots \& \alpha_r$ , и  $\varphi' = \gamma_1 \& \dots \& \gamma_r$ . Зафиксируем  $j \in \{1, \dots, r\}$ . Пусть  $\alpha_j = w_1 B_s t$ . Конъюнкт  $\alpha_j$  получен из конъюнкта  $\gamma_j = w_1 B w_2$  правила исходной грамматики  $G$ .

По построению,  $st = w_2 u$ , и по предыдущим двум утверждениям  $L_{G'}(B_s) = L_G(B)s$ .

Таким образом,  $L_{G'}(\alpha_j) = L_{G'}(w_1 B_s t) = w_1 L_G(B)st = L_G(w_1 B w_2)u = L_G(\gamma_j)u$ .

Так как такое равенство имеет место для всех  $j$ , то получаем

$$L_{G'}(\alpha_1) \cap \dots \cap L_{G'}(\alpha_r) = L_G(\gamma_1)u \cap \dots \cap L_G(\gamma_r)u$$

Что и требовалось доказать.

Если же  $\varphi = xu$ , то  $\varphi' = x$ , и утверждение тривиально. □

Теперь докажем, что в  $G'$  нет коротких правил.

Уже известно, что  $L_{G'}(A_u) = L_G(A)u$ , поэтому, если  $|u| = k - 1$ , то  $A_u$  не задаёт строк длины менее  $k - 1$ , и, следовательно, для таких нетерминалов коротких правил нет.

Покажем, что нет коротких правил и для нетерминалов  $A_u \in N'$  с  $|u| < k - 1$ .

Для начала докажем ещё пару несложных вспомогательных утверждений.

**Утверждение 17.** Для каждого конъюнкта  $\alpha_j = w_1 B_s t$  правила  $A_u \rightarrow \alpha_1 \& \dots \& \alpha_r$  в  $G'$  верно

- $|s| \geq |u|$
- Если  $|t| > 0$ , то  $|s| = k - 1$ .

*Доказательство.* По построению конъюнкта  $\alpha_j = w_1 B_s t$  был получен из конъюнкта  $\gamma_j = w_1 B w_2$  некоторого правила  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ , причём  $s = \text{First}_{k-1}(w_2 u)$  и  $st = w_2 u$ .

Поскольку  $|u| \leq k - 1$ , то  $|u| = |\text{First}_{k-1}(u)| \leq |\text{First}_{k-1}(w_2 u)| = |s|$ , и тем самым первая часть доказана.

Если  $|t| > 0$ , то,  $|\text{First}_{k-1}(w_2 u)| < |w_2 u|$ , и значит  $|s| = |\text{First}_{k-1}(w_2 u)| = k - 1$ .  $\square$

**Утверждение 18.** Пусть существует дерево разбора  $G'$ , в котором  $B_s$  задаёт  $xs$  по правилу  $B_s \rightarrow \varphi$ , полученному из правила  $B \rightarrow \varphi'$  исходной грамматики, и за поддеревом  $B_s$  следует строка  $y$ .

Тогда существует дерево разбора  $G$ , в котором  $B$  задаёт  $x$  по правилу  $B \rightarrow \varphi'$ , и за поддеревом  $B$  следует строка  $sy$ .

Кроме того, если  $|s| < k - 1$ , то  $y = \varepsilon$ .

*Доказательство.* Применим индукцию по глубине поддерева  $B_s$  в дереве разбора.

**Базовый случай.** Пусть  $B_s$  является корнем всего дерева разбора, то есть  $B_s = S_\varepsilon$ . Так как правее всего дерева разбора листьев нет, то  $y = \varepsilon$ .

Так как  $xs \in L_{G'}(\varphi)$ , то из утверждения 16 следует, что  $x \in L_G(\varphi')$ , и тем самым  $S$  задаёт  $x$  по правилу  $\varphi'$ .

В соответствующем дереве разбора  $S$  является корнем, и поэтому за ним следует строка  $\varepsilon = sy$ , что и требовалось доказать.

**Индукционный переход.** Пусть  $A_u$  — родитель  $B_s$  в дереве разбора. К  $A_u$  применяется некоторое правило  $A_u \rightarrow w_1 B_s t \& \alpha_1 \& \dots \& \alpha_r$ , полученное из правила  $A \rightarrow w_1 B w_2 \& \gamma_1 \& \dots \& \gamma_r$  исходной грамматики, где  $st = w_2 u$ .

Обозначим за  $y'$  строку, которая следует за поддеревом  $A_u$ , так что  $y = ty'$ .

Так как глубина  $B_s$  строго больше глубины  $A_u$  в дереве разбора, то к  $A_u$  применимо индукционное предположение, и тем самым существует дерево разбора с поддеревом  $A$ , такое что  $A$  задаёт  $w_1 x w_2$

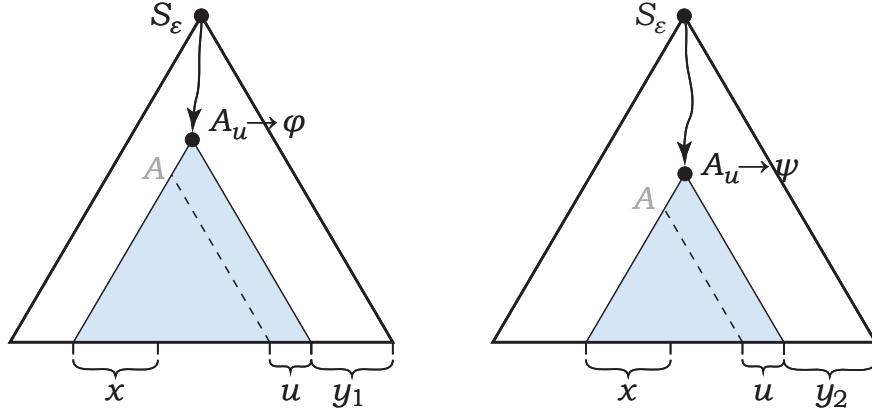


Рис. 12: Деревья  $D_1$  и  $D_2$  из утверждения 19

по правилу  $A \rightarrow w_1 B w_2 \& \gamma_1 \& \dots \& \gamma_r$ , и за поддеревом следует строка  $uy' \in \text{Follow}(A)$ .

В этом дереве разбора поддерево  $B$  задаёт строку  $x$ , и за поддеревом  $B$  следует строка  $w_2 uy' = sty' = sy$ , и первая часть утверждения 18 доказана.

Пусть теперь  $|s| < k - 1$ . Из утверждения 17 следует, что  $|s| \geq |u|$ , причём если  $|t| > 0$ , то  $|s| = k - 1$ .

Следовательно  $|u| < k - 1$  и  $t = \epsilon$ . К  $A_u$  применимо индукционное предположение, и значит из  $|u| < k - 1$  следует  $y' = \epsilon$ . Таким образом  $y = ty' = \epsilon$ , и второе утверждение доказано.

□

По предыдущему утверждению в деревьях разбора  $G'$  за поддеревьями  $A_u$  с  $|u| < k - 1$  не может следовать непустых строк, и тем самым в грамматике  $G'$  отсутствуют короткие правила.

Остаётся доказать, что  $G'$  является линейной  $\text{LL}(k)$  грамматикой. Линейность  $G'$  видна из построения.

**Утверждение 19.** *Если  $G$  принадлежит классу  $\text{LL}(k)$ , то  $G'$  — тоже.*

*Доказательство.* Рассмотрим два дерева разбора  $D_1$  и  $D_2$  грамматики  $G'$ , такие что в каждом из них есть поддеревья  $A_u$ , и обоих деревьях первые  $k$  листьев, начиная с самых левых листьев поддеревьев  $A_u$  образуют одну и ту же строку  $x$ .

Пусть в дереве  $D_1$  поддерево  $A_u$  задаёт строку  $ru$  по правилу  $A_u \rightarrow \varphi$ , и за поддеревом  $A_u$  следует строка  $y_1$ , а в дереве  $D_2$  поддерево  $A_u$  задаёт строку  $qu$  по правилу  $A_u \rightarrow \psi$ , и за поддеревом  $A_u$  следует строка  $y_2$ , как показано на рисунке 12. Покажем, что  $\varphi = \psi$ .

Правила  $A_u \rightarrow \varphi$  и  $A_u \rightarrow \psi$  были получены из правил исходной грамматики  $A \rightarrow \varphi'$  и  $A \rightarrow \psi'$  соответственно. По утверждению 18 существуют деревья разбора  $D'_1$  и  $D'_2$ , такие что в каждом из них есть поддерево  $A$ , в  $D'_1$  поддерево  $A$  задаёт  $p$  по правилу  $A \rightarrow \varphi'$ , и за поддеревом  $A$  следует строка  $uy_1$ , а в  $D'_2$  поддерево  $A$  задаёт  $q$  по правилу  $A \rightarrow \psi'$ , и за поддеревом  $A$  следует строка  $uy_2$ .

Тогда первые  $k$  листьев этих деревьев разбора, начиная с самых левых листьев поддеревьев  $A$  в деревьях  $D'_1$  и  $D'_2$  образуют строки  $\text{First}_k(puy_1)$  и  $\text{First}_k(quy_2)$  соответственно.

Так как  $\text{First}_k(puy_1) = \text{First}_k(quy_2) = x$ , и грамматика  $G$  принадлежит классу  $\text{LL}(k)$ , то  $\varphi' = \psi'$ , а значит и  $\varphi = \psi$ .

Тогда можно положить  $T_{G'}(A_u, x) = A_u \rightarrow \varphi$ , и построенная таким образом частичная функция будет корректной  $\text{LL}(k)$  таблицей для грамматики  $G'$ .  $\square$

Таким образом грамматика  $G'$  принадлежит классу  $\text{LL}(k)$ , что завершает доказательство корректности построения.  $\square$

## 9 Конъюнктивные грамматики: приведение к виду $\text{LL}(1)$

После того, как из грамматики удалены все короткие правила, её можно преобразовать к виду  $\text{LL}(1)$  так же, как это делалось в неконъюнктивном случае.

Сперва снова избавимся от так называемых цепных правил.

**Определение 13.** Правило  $A \rightarrow \alpha_1 \& \dots \& \alpha_r$  конъюнктивной грамматики  $G = (\Sigma, N, R, S)$  называется **цепным**, если каждый конъюнкт  $\alpha_j$ ,  $j \in \{1, \dots, r\}$  состоит из единственного нетерминала, то есть  $\alpha_j = B$ ,  $B \in N$ .

**Лемма 8.** Для каждой конъюнктивных линейной  $\text{LL}(k)$  грамматики  $G = (\Sigma, N, R, S)$  без коротких правил существует конъюнктивная линейная  $\text{LL}(k)$  грамматика  $G' = (\Sigma, N, R', S)$  без коротких правил, задающая тот же язык и не содержащая цепных правил.

*Доказательство.* Доказательство непосредственно обобщает аналогичное доказательство леммы 2.  $\square$

Докажем теперь аналог утверждения 8.

**Утверждение 20.** Пусть  $G = (\Sigma, N, R, S)$  — конъюнктивная линейная  $\text{LL}(k)$  грамматика без коротких и цепных правил. Тогда для любого нетерминала  $A \in N$  если  $x \in L(A)$  и  $|x| = k - 1$ , то либо в  $G$  не существует деревьев разбора, в которых есть поддерево  $A$ , задающее

строку  $x$ , и за поддеревом  $A$  следует непустая строка, либо в  $R$  есть правило  $A \rightarrow x$ .

*Доказательство.* Предположим противное. Пусть существует дерево разбора с поддеревом  $A$ , такое что  $A$  задаёт  $x$  по некоторому правилу  $A \rightarrow \varphi$ ,  $|x| = k - 1$ , и за поддеревом  $A$  следует некоторая непустая строка. Обозначим за  $c$  первый символ этой строки.

Тогда  $T(A, xc) = A \rightarrow \varphi$ . Если  $\varphi \in \Sigma^*$ , то  $\alpha = x$  и всё доказано.

Предположим,  $\varphi = \alpha_1 \& \dots \& \alpha_r$ . Так как в  $G$  отсутствуют цепные правила, то для некоторого конъюнкта  $\alpha_j = sBt$  выполняется  $|s| + |t| > 0$ . Тогда  $x = syt$ , где  $y \in L(B)$ , и значит  $|y| < |x| = k - 1$ .

Рассмотрим дерево разбора  $y$  из  $B$ . Любое самое нижнее правило в нём имеет вид  $C \rightarrow z$ , где  $|z| \leq |y| < k - 1$ .

Так как вершина  $C$  — потомок  $A$  в дереве разбора, и за  $A$  следует непустая строка, то за поддеревом  $C$  также следует непустая строка.

Тем самым правило  $C \rightarrow z$  короткое, что противоречит отсутствию в  $G$  коротких правил.  $\square$

Опишем теперь основное построение.

**Лемма 9.** Для каждой конъюнктивной линейной  $LL(k)$  грамматики  $G = (\Sigma, N, R, S)$  без коротких и цепных правил существует конъюнктивная линейная  $LL(1)$  грамматика  $G'$ , задающая тот же язык.

*Доказательство.* Как и в лемме 3, нетерминалы новой грамматики  $G' = (\Sigma, N', R', \varepsilon S)$ , имеют вид  $_u A$ , где  $A \in N$  и  $u \in \Sigma^{\leq k-1}$ .

Аналогично неконъюнктивному случаю можно определить синтаксический анализатор, который строит дерево разбора строки по мере прочтения её слева направо, определяя нужные правила по очередным  $k$  символам строки с помощью  $LL(k)$  таблицы.

Левый нижний индекс  $u$  нетерминала  $_u A$  будет выполнять роль буфера, в котором хранится до  $k - 1$  последних символов, прочтённых синтаксическим анализатором.

Начальным символом  $G'$  является  $\varepsilon S$ , что соответствует  $S$  с пустым буфером.

Итак,  $N' = \{_u A \mid A \in N, u \in \Sigma^{\leq k-1}\}$ . Правила грамматики  $G'$  представляются объединением трёх множеств  $R_1, R_2$  и  $R_3$ .

Множество правил  $R_1$  реализуют заполнение буфера. Для каждого нетерминала  $_u A$  с  $|u| < k - 1$ , и для каждого символа  $a \in \Sigma$ , в  $G'$  есть правило, заносящее этот символ в буфер.

$$_u A \rightarrow a \ _{ua} A$$

Правила  $R_2$  используются, когда буфер уже заполнен, и синтаксический анализатор  $G'$  может понять, какое правило исходной грамматики следует применить. Для каждого  $_u A \in N'$  и  $a \in \Sigma$ , где  $|u| = k - 1$  и значение  $T(A, ua)$  определено, в  $G'$  есть правило, получающееся *откусыванием* строки  $u$  из правила  $(A \rightarrow \varphi) = T(A, ua)$ . Если  $\varphi \in \Sigma^*$ , тогда  $\varphi = us$ , где  $s \in \Sigma^*$ , и соответствующее правило в  $G'$  имеет вид

$$_u A \rightarrow s$$

Если  $\varphi$  имеет вид  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ , то соответствующее правило  $G'$  имеет вид  $_u A \rightarrow \alpha_1 \& \dots \& \alpha_r$ , где каждый конъюнкт  $\alpha_j$  получается откусыванием  $u$  из начала конъюнкта  $\gamma_j$ , как это было в лемме 3. Если  $\gamma_j = sBt$ , где  $s, t \in \Sigma^*$ ,  $B \in N$ , то одна из строк  $u$  и  $s$  является префиксом другой, и имеем два случая:

$$\begin{aligned} \alpha_j &= s'_\varepsilon Bt, && \text{если } s = us', s' \in \Sigma^* \\ \alpha_j &= vBt, && \text{если } u = sv, v \in \Sigma^+ \end{aligned}$$

Наконец, правила  $R_3$  нужны для случая, когда вся строка уже прочитана анализатором, и ему нечего заносить в буфер. А именно, для каждого  $_u A \in N'$ , где  $|u| \leq k - 1$  и значение  $T(A, u)$  определено, грамматика  $G'$  содержит пустое правило.

$$_u A \rightarrow \varepsilon$$

Заметим, что  $R_1 \cap (R_2 \cup R_3) = \emptyset$ , однако множества  $R_2$  и  $R_3$  могут пересекаться по некоторым правилам вида  $_u A \rightarrow \varepsilon$ ,  $|u| = k - 1$ . Если известно, что правило  $_u A \rightarrow \varphi$  лежит в  $R_2$ , то всегда можно однозначно восстановить правило  $A \rightarrow \varphi'$  исходной грамматики, из которого оно получено, исходя из определения. Если  $\varphi \in \Sigma^*$ , то  $\varphi' = u\alpha$ , если  $\varphi = \alpha \& \dots \& \alpha_r$ , то  $\varphi' = \gamma_1 \& \dots \& \gamma_r$ , где каждый конъюнкт  $\gamma_j$  получается из конъюнкта  $\alpha_j$  следующим образом. Если  $\alpha_j = s'_\varepsilon Bt$ , то  $\gamma_j = us'Bt$ , и если  $\alpha_j = vBt$ , то имеем  $u = sv$ , и  $\gamma_j = sBt$ .

Доказательство того, что  $G'$  обладает свойством  $LL(1)$  и задаёт тот же язык, что и  $G$ , даётся в серии утверждений.

Сначала установим связь между языками  $L_G(A)$  и  $L_{G'}(_u A)$ . В конъюнктивном случае равенство  $L_{G'}(_u A) = \{ w \mid uw \in L_G(A) \}$ , вообще говоря, не выполняется. Причина этого кроется в том, что, в отличие от неконъюнктивного случая, может оказаться, что некоторая строка  $w$  задаётся нетерминалом  $A$ , однако дерева разбора с корнем  $S$  и поддеревом  $A$ , задающим  $w$  не существует.

Следующие два утверждения показывают, как соотносятся между собой множества  $L_{G'}(_u A)$  и  $L_G(A)$ .

Сначала определим соответствие между деревьями разбора  $G'$  и деревьями разбора  $G$ .

**Определение 14.** Пусть  $D$  и  $D'$  — деревья разбора  $G$  и  $G'$  соответственно. Корни  $D$  и  $D'$  не обязательно помечены начальными символами грамматик. Пусть  $V$  и  $V'$  — множества вершин  $D$  и  $D'$  соответственно.

Отображение  $f : V' \rightarrow V$  назовём назовём **гомоморфизмом** деревьев  $D$  и  $D'$ , если оно обладает следующим свойством. Пусть вершина  $v' \in V'$  помечена нетерминалом  $_u A \in N'$ , и её поддерево задаёт строку  $x$ . Тогда:

1. Вершина  $v = f(v')$  помечена нетерминалом  $A \in N$  и поддерево  $v$  задаёт строку  $u x$ .
2. Пусть путь от вершины  $v' \in V'$ , помеченной нетерминалом  $_u A \in N'$ , к некоторому листу начинается с нескольких (возможно, нуля) правил, наращивающих буфер, а затем — правила  $_u' A \rightarrow \varphi$ , полученного из правила  $A \rightarrow \varphi'$  исходной грамматики (соответствующие правила выписаны ниже).

$$\begin{aligned}
 _u A &\rightarrow a_1 {}_{ua_1} A \\
 {}_{ua_1} A &\rightarrow a_2 {}_{ua_1 a_2} A \\
 &\vdots \\
 {}_{ua_1 \dots a_{m-1}} A &\rightarrow a_m {}_{u'} A \\
 {}_{u'} A &\rightarrow \varphi
 \end{aligned}$$

Тогда к вершине  $f(v)$  применяется правило  $A \rightarrow \varphi'$ .

Если такое отображение  $f$  существует, то деревья  $D$  и  $D'$  будем называть **гомоморфными**.

**Утверждение 21.** Если существует дерево разбора  $D'$  строки  $x$  из нетерминала  $_u A \in N'$ , то существует гомоморфное ему дерево разбора  $D$  строки  $u x$  из нетерминала  $A \in N$ .

*Доказательство.* Доказательство проводится индукцией по высоте дерева разбора  $x$  из  $_u A$ .

**Базовый случай:**  $x$  задаётся одним правилом  $_u A \rightarrow x$ . Все правила  $R_1$  содержат нетерминал, поэтому  $_u A \rightarrow x$  может быть либо из  $R_2$ , либо из  $R_3$ .

В первом случае  $_u A \rightarrow x$ , получено из правила  $A \rightarrow ux$  в  $G$ , и несложно проверить, что соответствующие поддеревья высоты 1 гомоморфны.

Во втором случае  $T(A, u)$  определено и  $x = \varepsilon$ . Так как  $T(A, u)$  определено и  $u < k$ , то  $u$  — суффикс входной строки.

Тогда по определению LL-таблицы существует дерево разбора с поддеревом  $A$ , такое что  $A$  задаёт некоторую строку  $x'$ , и за поддеревом следует строка  $t$ , так что  $x't = u$ .

Если  $|x'| = k - 1$ , то, поскольку  $|u| \leq k - 1$ , то  $x' = u$ . Если же  $|x'| < k - 1$ , то из отсутствия в  $G$  коротких правил, следует, что  $t = \varepsilon$  и тем самым снова  $x' = x't = u$ .

Так или иначе, получаем, что  $ux = u = x'$  задаётся  $A$ , и отображение, переводящее вершину  $_u A$  в корень поддерева  $A$ , задающего  $ux$ , есть требуемый гомоморфизм деревьев. Заметим, что в этом случае второе условие из определения гомоморфизма выполняется тривиальным образом, так как в дереве  $_u A$  просто нет правил из  $R_2$ .

**Индукционный переход.** Пусть  $_u A$  задаёт  $x$  по правилу  $_u A \rightarrow \varphi$ , и  $\varphi$  содержит нетерминал.

Правило  $_u A \rightarrow \varphi$  лежит либо в  $R_1$ , либо в  $R_2$ , соответственно нужно разобрать два случая.

Пусть  $_u A \rightarrow \varphi$  лежит в  $R_2$ , то есть  $_u A \rightarrow \alpha_1 \& \dots \& \alpha_r$ , где каждый конъюнкт  $\alpha_j$  получен откусыванием  $u$  из начала конъюнкта  $\gamma_j$  соответствующего правила  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$  грамматики  $G$ .

Зафиксируем  $j \in \{1, \dots, r\}$ . Пусть  $\gamma_j = sBt$ . В соответствии с определением  $R_2$ , есть два случая, в зависимости от того, какая из строк  $u$  и  $s$  длиннее.

- Если  $|u| > |s|$ , то  $\alpha_j = _v Bt$ , где  $u = sv$ . Тогда  $x = yt$  для некоторого  $y \in L_{G'}(_v B)$ . Высота дерева разбора  $y$  из  $_v B$  меньше высоты дерева разбора  $x$  из  $_u A$ .

Тогда, по предположению индукции, существует дерево разбора  $vy$  из  $B$ , гомоморфное поддереву  $_v B$ , и в частности  $ux = uyt = svyt \in L_G(sBt) = L_G(\gamma_j)$ .

- Если  $|u| \leq |s|$ , то  $\alpha_j = s'_\varepsilon Bt$  где  $us' = s$ . Тогда  $x = s'yt$ , где  $y \in L_{G'}(\varepsilon B)$ .

По предположению индукции, существует дерево разбора  $y$  из  $B$ , гомоморфное поддереву  $\varepsilon B$ , и в частности  $ux = us'yt = syt \in L_G(sBt) \in L_G(\gamma_j)$ .

Пусть  $D_j$  обозначает дерево разбора с корнем  $B$ , гомоморфное поддереву  $D'_j$  с корнем  $_v B$  или  $\varepsilon B$ , в зависимости от того, какой из случаев имеет место.

Рассмотрим дерево разбора  $D$  с корнем  $A$ , такое что к  $A$  применяется правило  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ , и нетерминалу из каждого конъюнкта  $\gamma_j$  соответствует поддерево  $D_j$ .

Тогда все конъюнкты  $\gamma_j$  задают одну и ту же строку  $ux$ , и тем самым  $D$  является корректным деревом разбора  $ux$  из  $A$ .

Гомоморфизм между деревьями  $D'$  и  $D$  получается следующим образом: корень  $D'$  отображается в корень  $D$ , а все остальные вершины — согласно гомоморфизмам между  $D'_j$  и  $D_j$ .

Пусть теперь  $(_u A \rightarrow \varphi) \in R_1$  — правило, наращивающее буфер.

Тогда  $\varphi = a_{ua}A$  для некоторого  $a \in \Sigma$ . Значит  $x = ay$ , где  $y \in L_{G'}(_u A)$ .

Следовательно, по предположению индукции, существует гомоморфизм между поддеревом  $_u A$  и некоторым деревом разбора  $ua y = ux$  из  $A$ . Этот гомоморфизм можно продолжить на корень  $_u A$ , отобразив его в корень дерева разбора  $ux$  из  $A$ .

□

Из последнего утверждения сразу вытекает полезное следствие:

**Утверждение 22.** *Пусть существует дерево разбора  $G'$ , в котором  $_v B$  задаёт  $x$  по правилу  $_v B \rightarrow \varphi$ , и за поддеревом  $_v B$  следует строка  $y$ .*

1. *Тогда существует дерево разбора  $G$ , в котором  $B$  задаёт  $vx$  и за поддеревом  $B$  следует строка  $y$ .*
2. *Если, к тому же, правило  $_v B \rightarrow \varphi$  получено из правила исходной грамматики  $B \rightarrow \varphi'$ , то существует дерево разбора  $G$ , в котором  $A$  задаёт  $vx$  по правилу  $A \rightarrow \varphi'$  и за поддеревом  $A$  следует строка  $y$ .*

**Утверждение 23.** *Если существует дерево разбора  $G$  с поддеревом  $A$ , задающим строку  $ux$ , то  $x \in L_{G'}(_u A)$ .*

*Доказательство.* Сначала разберём случай, когда  $|ux| < k$  и  $T(A, ux)$  определено. Тогда, по построению  $G'$  содержит правило  $_u A \rightarrow \varepsilon$ .

Пусть  $x = x_1 \dots x_m$ . Буфер  $u$  нетерминала  $_u A$  может быть расширен до  $ux$  с помощью следующих правил.

$$\begin{aligned} _u A &\rightarrow x_1 \ _u x_1 A \\ _u x_1 A &\rightarrow x_2 \ _u x_1 x_2 A \\ _u x_1 \dots x_{m-1} A &\rightarrow x_m \ _u x A \end{aligned}$$

Эта последовательность правил, вместе с правилом  $_u x A \rightarrow \varepsilon$  составляют вывод  $x$  из  $_u A$ . Таким образом,  $x \in L_{G'}(_u A)$ .

Теперь предположим, что либо  $|ux| \geq k$ , либо  $|ux| = k - 1$ , но значение  $T(A, ux)$  не определено.

Если  $|ux| = k - 1$ , то из того, что  $T(A, ux)$  не определено, следует, что за поддеревом  $A$ , задающим  $ux$ , следует некоторая непустая строка. Определим  $c$  как первый символ этой строки.

Положим  $n = k - |u| - 1$  и пусть  $a$  будет либо  $x_{n+1}$ , в случае  $|ux| \geq k$ , либо  $c$ , в случае  $|ux| = k - 1$ .

Обозначим за  $u'$  строку  $ux_1 \dots x_n$ .

Тогда  $|u'| = k - 1$  и  $T(A, u'a) = A \rightarrow \varphi'$ , где  $A \rightarrow \varphi'$  — правило, по которому  $A$  задаёт  $ux$ .

Буфер  $_u A$  может быть пополнен до  $u'$  с помощью следующих правил.

$$\begin{aligned} {}_u A &\rightarrow x_1 {}_{ux_1} A \\ {}_{ux_1} A &\rightarrow x_2 {}_{ux_1 x_2} A \\ {}_{ux_1 \dots x_{n-1}} A &\rightarrow x_n {}_{u'} A \end{aligned}$$

Тогда, так как  $T(A, u'a) = A \rightarrow \varphi'$ , грамматика  $G'$  содержит правило  ${}_{u'} A \rightarrow \varphi$ , где каждый конъюнкт  $\varphi$  получается откусыванием  $u$  из соответствующего конъюнкта  $\varphi'$ .

Остается доказать, что  $\varphi'$  задаёт строку  $x_{n+1} \dots x_m$ . Воспользуемся индукцией по высоте дерева разбора  $ux$  из  $A$ .

Заметим, что если  $\varphi$  задаёт строку  $x_{n+1} \dots x_m$ , то последовательность правил выше, вместе с правилом  ${}_{u'} A \rightarrow \varphi$ , составляет вывод строки  $x_1 \dots x_m = x$  из  $_u A$ , и доказательство будет окончено. Поэтому можно считать, что предположением индукции служит всё доказываемое утверждение.

**Базовый случай:**  $ux$  задаётся по правилу  $A \rightarrow ux$ . Тогда

$$\varphi' = T(A, u'a) = A \rightarrow ux, \text{ и } \varphi = x_{n+1} \dots x_m.$$

**Индукционный переход:**  $ux$  задаётся по правилу  $A \rightarrow \gamma_1 \& \dots \& \gamma_r$ .

Тогда  $\varphi = \alpha_1 \& \dots \& \alpha_r$ , где каждый конъюнкт  $\alpha_j$  получается откусыванием  $u'$  из конъюнкта  $\gamma_j$ .

Зафиксируем  $j \in \{1, \dots, r\}$ . Пусть  $\gamma_j = sBt$ .

Тогда  $ux = syt$ , где  $y \in L_G(B)$ . и  $\alpha_j$  получается откусыванием  $u'$  из строки  $sBt$ .

В соответствии с определением  $R_2$  имеем два случая, в зависимости от того, какая из строк  $u'$  и  $s$  длиннее.

Если  $|s| \geq |u'|$ , то  $\alpha_j = s'{}_\varepsilon Bt$ , где  $u's' = s$ .

Высота дерева разбора  $y$  из  $B$  меньше высоты дерева разбора  $ux$  из  $A$ . Тогда по предположению индукции  $y \in L_{G'}({}_\varepsilon B)$ .

Следовательно,  $u's'yt = syt = ux$ , и значит  $s'yt = x_{n+1} \dots x_m \in L_{G'}(\alpha_j)$ .

Если же  $|s| < |u'|$ , то  $\alpha_j = {}_vBt$ , где  $sv = u'$ .

Чтобы воспользоваться предположением индукции для нетерминалов  $B$  и  ${}_vB$  и строки  $y$ , необходимо показать, что  $v$  является префиксом  $y$ .

Так как в  $G$  нет коротких правил, то либо  $|y| \geq k - 1$ , либо  $t = \varepsilon$ .

Если  $t = \varepsilon$ , то  $ux = sy$ , и поскольку  $sv = u'$  является префиксом  $ux$ , то  $v$  является префиксом  $y$ .

Если же  $|y| = k - 1$ , то и  $|sy| \geq k - 1$ . Поскольку  $u'$  — это префикс  $ux = sy$ , и  $|u'| \leq k - 1$ , то строка  $u' = sv$  является префиксом  $sy$ , и следовательно  $v$  — префикс  $y$ .

Таким образом,  $y = vy'$  для некоторой строки  $y' \in \Sigma^*$ , и по предположению индукции  $y' \in L_{G'}({}_vB)$ .

Получаем  $u'y't = u'syt = ux$ , и значит  $y't = x_{n+1} \dots x_m \in L_{G'}(\alpha_j)$ .

Следовательно  $x_{n+1} \dots x_m \in L_{G'}(\alpha_j)$  для каждого  $j \in \{1, \dots, r\}$ . Значит  ${}_uA$  задаёт  $x_{n+1} \dots x_m$  по правилу  ${}_uA \rightarrow \alpha_1 \& \dots \& \alpha_r = \varphi$ , что и требовалось доказать.

□

Грамматика  $G'$  линейна по построению и по утверждениям 21 и 23  $L(G') = L_{G'}(\varepsilon S) = L_G(S) = L(G)$ . Остается показать, что  $G'$  принадлежит классу  $LL(1)$ .

**Утверждение 24.** Грамматика  $G'$  принадлежит классу  $LL(1)$ .

*Доказательство.* Рассмотрим два дерева разбора  $D_1$  и  $D_2$  грамматики  $G'$ , в каждом из которых есть поддерево  ${}_uA$ , и пусть строки, начинающиеся с самых левых листьев этих поддеревьев, начинаются на одну и ту же букву или обе пусты. Обозначим эту букву за  $x$  (если обе строки пусты, то  $x = \varepsilon$ ).

Пусть в  $D_1$  поддерево  ${}_uA$  задаёт строку  $p$  по правилу  ${}_uA \rightarrow \varphi$ , и за поддеревом  ${}_uA$  следует строка  $y_1$ , а в  $D_2$  поддерево  ${}_uA$  задаёт строку  $q$  по правилу  ${}_uA \rightarrow \psi$ , и за поддеревом  ${}_uA$  следует строка  $y_2$ . Покажем, что  $\varphi = \psi$ .

Доказательство проводится отдельно для случаев  $|u| < k - 1$  и  $|u| = k - 1$ . Пусть сначала  $|u| < k - 1$ .

Тогда каждое из правил  ${}_uA \rightarrow \varphi$  и  ${}_uA \rightarrow \psi$  лежит в  $R_1$  или  $R_3$ . Разберём случаи.

- Если оба правила лежат в  $R_3$ , то  $\varphi = \psi = \varepsilon$ .

- Если оба правила лежат в  $R_1$ , то  $\varphi = a \cdot uA$  и  $\psi = b \cdot ubA$  для некоторых символов  $a$  и  $b$ . Тогда  $x = a = b$ , и значит  $\varphi = \psi$ .
- Пусть одно из правил лежит в  $R_1$ , а другое — в  $R_3$ . Не умаляя общности,  $\varphi = a \cdot uA$  для некоторого  $a \in \Sigma$ , а  $\psi = \varepsilon$ .

Тогда  $\varepsilon \in L_{G'}(uA)$ , и  $u \in L_G(A)$  по утверждению 21. Поскольку в  $G$  нет коротких правил, и  $|u| < k - 1$ , то  $y_2 = \varepsilon$ , и так как  $x \in \text{First}_k(L_{G'}(\psi)y_2)$ , то  $x = \varepsilon$ . В то же время из того, что  $\varphi = a \cdot uA$  следует, что  $x = a$ . Полученное противоречие показывает, что этот случай невозможен.

Пусть теперь  $|u| = k - 1$ . Тогда, каждое из правил  $uA \rightarrow \varphi$ ,  $uA \rightarrow \psi$  лежит в  $R_2$  или в  $R_3$ . Снова разберём случаи.

- Если оба правила лежат в  $R_3$ , то  $\varphi = \psi = \varepsilon$ .
- Пусть, скажем,  $uA \rightarrow \varphi$ , лежит в  $R_2$  и получено из правила  $A \rightarrow \varphi'$ , а  $uA \rightarrow \psi$  лежит в  $R_3$ . Тогда  $\psi = \varepsilon$ , и значит, во-первых,  $u \in L_G(A)$ , и во-вторых,  $x = \text{First}_1(y_2)$ .

Предположим,  $\varphi$  задаёт пустую строку. Тогда  $\varphi'$  задаёт  $u$  по утверждению 10. По определению  $R_2$  имеем  $(A \rightarrow \varphi') = T(A, ua)$  для некоторого  $a \in \Sigma$ , и поэтому существует дерево разбора с поддеревом  $A$ , такое что  $A$  задаёт  $u$  по правилу  $A \rightarrow \varphi'$ , и строка, которая следует за поддеревом  $A$ , начинается с символа  $a$ .

Тогда  $\alpha = u$  по утверждению 20, и так как  $\varphi$  получается откусыванием  $u$  из  $\varphi'$ , то  $\varphi = \varepsilon = \psi$ .

Пусть теперь  $\varphi$  не задаёт пустой строки, и тем самым  $x = \text{First}_1(L_{G'}(\varphi))$ .

То, что  $\varepsilon \notin \text{First}_1(L_{G'}(\varphi))$  уже предполагается. Пусть  $c \in \text{First}_1(L_{G'}(\gamma_1))$ , где  $c \in \Sigma$ . Тогда  $T(A, uc) = (A \rightarrow \varphi')$ .

Из утверждения 22 следует, существует дерево разбора с поддеревом  $A$ , такое что  $A$  задаёт  $u$ , и за поддеревом  $A$  следует строка  $y_2$ .

Так как  $|u| = k - 1$  и  $y_2 \neq \varepsilon$ , то из утверждения 8 следует, что  $A$  задаёт  $u$  по правилу  $A \rightarrow u$ .

Предположим, что  $\text{First}_1(y_2) = c$ . Тогда по определению LL( $k$ )-таблицы имеем  $T(A, uc) = (A \rightarrow u)$ . Поэтому  $\varphi' = u$ , и снова  $\varphi = \varepsilon = \psi$ .

- Пусть теперь правила  $A \rightarrow \varphi$  и  $A \rightarrow \psi$  были получены из правил исходной грамматики  $A \rightarrow \varphi'$  и  $A \rightarrow \psi'$  соответственно. По утверждению 22 существуют деревья разбора  $D'_1$  и  $D'_2$ , такие что в обоих деревьях есть поддерево  $A$ , в  $D'_1$  поддерево  $A$  задаёт  $up$  по правилу

$A \rightarrow \varphi'$ , и за поддеревом  $A$  следует строка  $y_1$ , а в  $D_2$  поддерево  $A$  задаёт  $uq$  по правилу  $A \rightarrow \psi'$ , и за поддеревом  $A$  следует строка  $y_2$ .

Тогда первые  $k$  листьев этих деревьев разбора, начиная с самых левых листьев поддеревьев  $A$  и  $A$  образуют строки  $\text{First}_k(py_1)$  и  $\text{First}_k(qy_2)$  соответственно.

Так как  $\text{First}_k(py_1) = \text{First}_k(qy_2)$ , и грамматика  $G$  принадлежит классу  $\text{LL}(k)$ , то  $\varphi' = \psi'$ , а значит и  $\varphi = \psi$ .

Тогда можно положить  $T_{G'}(uA, x) = uA \rightarrow \varphi$ , и построенная таким образом частичная функция будет корректной  $\text{LL}(k)$  таблицей для грамматики  $G'$ .  $\square$

Последнее утверждение завершает доказательство леммы 9.  $\square$

Вместе леммы 7, 8 и 9 составляют доказательство теоремы 3.

## 10 Заключение

Полученные результаты заставляют задуматься о нескольких близких вопросах. Неизбежен ли рост размера грамматики при преобразовании  $\text{LL}(k)$ -линейных конъюнктивных грамматик в  $\text{LL}(1)$ -линейные конъюнктивные? Существует ли иерархия  $\text{LL}(k)$ -конъюнктивных грамматик (без свойства линейности) по  $k$ ? Вообще, о классе  $\text{LL}(k)$ -конъюнктивных грамматик известно очень мало, и он ждёт своего исследователя.

## Список литературы

- [1993] M. Holzer, K.-J. Lange, “On the complexities of linear  $\text{LL}(1)$  and  $\text{LR}(1)$  grammars”, *Fundamentals of Computation Theory* (FCT 1993, Hungary, August 23–27, 1993), LNCS 710, 299–308.
- [1988] O. H. Ibarra, T. Jiang, B. Ravikumar, “Some subclasses of context-free languages in  $\text{NC}^1$ ”, *Information Processing Letters*, 29:3 (1988), 111–117.
- [1971] D. E. Knuth, “Top-down syntax analysis”, *Acta Informatica*, 1 (1971), 79–110.
- [1969] R. Kurki-Suonio, “Notes on top-down languages”, *BIT Numerical Mathematics*, 9:3 (1969), 225–238.
- [1968] P. M. Lewis II, R. E. Stearns, “Syntax-directed transduction”, *Journal of the ACM*, 15:3 (1968), 465–488.

- [2001] A. Okhotin, “Conjunctive grammars”, *Journal of Automata, Languages and Combinatorics*, 6:4 (2001), 519–535.
- [2011] A. Okhotin, “Expressive power of LL( $k$ ) Boolean grammars”, *Theoretical Computer Science*, 412:39 (2011), 5132–5155.
- [2019] A. Okhotin, I. Olkhovsky, “LL(1) linear grammars are as powerful as LL( $k$ ) linear grammars”, *Fifth Russian-Finnish Symposium on Discrete Mathematics* (RuFiDiM V, Veliky Novgorod, 19–22 May 2019).
- [2020] A. Okhotin, I. Olkhovsky, “On the transformation of LL( $k$ )-linear grammars to LL(1)-linear”, *Computer Science in Russia* (CSR 2020, Ekaterinburg, Russia, 29 June–3 July 2020), LNCS 12159, to appear.
- [1970] D. J. Rosenkrantz, R. E. Stearns, “Properties of deterministic top-down grammars”, *Information and Control*, 17 (1970), 226–256.