

С. Ю. Соловьев¹

ОСОБЕННОСТИ КАНОНИЧЕСКИХ РАЗДЕЛЕННЫХ ГРАММАТИК

Рассматривается класс канонических разделенных грамматик, способных породить те же языки, что и разделенные грамматики общего вида. Приводятся основные свойства и два характеристических признака канонических грамматик. Предлагается метод унификации нетерминальных символов и доказывается единственность канонического представления разделенной грамматики.

Ключевые слова: разделенные грамматики, эквивалентность.

1. Введение. В 1974 г. Бруно Курсель [1] доказал существование канонического представления разделенных грамматик в нормальной форме Грейбах. В настоящей работе развивается иной подход к построению канонических грамматик, согласно которому условие нормализации

¹ Факультет ВМК МГУ, проф., д.ф.-м.н., e-mail: soloviev@glossary.ru

заменяется требованием обязательной альтернативности. Каждая каноническая грамматика такого рода содержит наименьшее количество нетерминальных символов по сравнению с прочими эквивалентными ей разделенными грамматиками. В рамках предложенного подхода доказываются два признака и единственность канонического представления; попутно предлагаются новые доказательства некоторых известных [1] утверждений.

2. Разделенные грамматики. Строительным материалом любой формальной грамматики являются символы двух непересекающихся алфавитов, первый из которых называется алфавитом терминальных символов (*терминалов*), а второй — алфавитом нетерминальных символов (*нетерминалов*). Из числа нетерминалов выделяется особый *начальный символ*. Везде далее используются обозначения: Σ — алфавит терминалов; N — алфавит нетерминалов; S — начальный символ; D — нетерминал из N ; N' — алфавит $N \setminus \{S\}$; a, b, c — терминалы из Σ ; A, B, C — нетерминалы из N' ; x, y, z — цепочки терминалов (*предложений*) из Σ^* ; α, β — цепочки из $(N \cup \Sigma)^*$; φ, ψ — цепочки из $(N' \cup \Sigma)^+$; μ, ρ, η — цепочки из $(N' \cup \Sigma)^*$.

Разделенной грамматикой [2] называется четверка $G = \langle N, \Sigma, P, S \rangle$, где P — множество *правил вывода* $D \rightarrow b\beta$, в которых каждой паре (D, b) отвечает не более одного правила. Правило вывода $D \rightarrow b\beta$ называется *D-правилом*, а цепочка $b\beta$ — *альтернативой* нетерминала D . В примерах принято задавать грамматики правилами вывода, из которых извлекаются остальные члены четверки. В литературе разделенные грамматики также именуются строгими разделенными грамматиками и простыми $LL(1)$ -грамматиками. Разделенные грамматики в нормальной форме Грейбах называются *s-грамматиками* [1].

Пусть G — разделенная грамматика и L, L_1 — некоторые языки, $L, L_1 \subseteq \Sigma^*$. Далее используются обозначения: $P(D)$ — множество всех D -правил из P ; $\hat{P}(N_X)$ — множество всех D -правил, где $D \in N_X$ и $N_X \subseteq N$; $R(G, D)$ — множество цепочек-альтернатив $\{\alpha: D \rightarrow \alpha \in P(D)\}$; $x||L$ — множество цепочек $\{z: xz \in L\}$; $|\alpha|$ — длина цепочки α ; e — цепочка нулевой длины; \times — операция произведения языков: $L \times L_1 \stackrel{\text{def}}{=} \{xy: x \in L, y \in L_1\}$; \Rightarrow — бинарное отношение непосредственного левого вывода: $\alpha_1 \Rightarrow \alpha_2$, если α_1 и α_2 можно представить в виде $xD\alpha_0$ и $xb\beta\alpha_0$, где $D \rightarrow b\beta$ — правило из P . В общем случае левый вывод $x_0D_0\beta_0 \Rightarrow^+ x_n$ имеет вид

$$x_0D_0\beta_0 \Rightarrow x_1D_1\beta_1 \Rightarrow \dots \Rightarrow x_{n-1}D_{n-1}\beta_{n-1} \Rightarrow x_n. \tag{1}$$

Производным языком для грамматики G и начальной цепочки α будем называть множество предложений $L(G, \alpha) = \{x: \alpha \Rightarrow^* x\}$. Язык, порождаемый разделенной грамматикой G , есть множество $L(G, S)$. В соответствии со сложившейся традицией язык $L(G, S)$ будем называть разделенным языком. Грамматики G и G_1 называются *эквивалентными*, если $L(G, S) = L(G_1, S)$.

Примером разделенной грамматики, демонстрирующим многие последующие рассуждения, является грамматика

$$\begin{array}{lcl} \hat{g}: & S \rightarrow bD & | cA, & L(\hat{g}, S) = \{c, ba, bb\} \times L(\hat{g}, A), \\ & A \rightarrow a & | bA \quad | cCB, & L(\hat{g}, A) = \{b, ca, cb\}^* \times \{a\}, \\ & B \rightarrow a & | bB \quad | cD, & L(\hat{g}, B) = L(\hat{g}, A), \\ & C \rightarrow a & | b, & L(\hat{g}, C) = \{a, b\}, \\ & D \rightarrow aA & | bB, & L(\hat{g}, D) = \{a, b\} \times L(\hat{g}, A) = L(\hat{g}, CA). \end{array}$$

Зафиксируем очевидные свойства разделенных грамматик и языков.

1. В разделенной грамматике G все языки $L(G, \varphi)$ являются разделенными.
2. Любой разделенный язык является *префиксным языком*, в котором никакие два предложения x и y не связаны отношением $x = yz$ для некоторого $z \neq e$.
3. Если $L = L_1 \times L_2$ и L_1 — префиксный язык, то $x||L = L_2$ для любого $x \in L_1$.
4. В выводе (1) D_i -правило, применяемое к $x_iD_i\beta_i$, однозначно определяется терминалом a , расположенным в позиции $|x_i| + 1$ каждой из цепочек x_{i+1}, \dots, x_n .

Лемма 1. Пусть $L_1 \times \{b\} = L_2 \times L_3$, где b — терминал из Σ и $L_1, L_2, L_3 \subseteq \Sigma^+$. Пусть, кроме того, L_1 — префиксный язык, а L_3 — язык, содержащий более одного предложения. Тогда существует язык $L'_3 \subseteq \Sigma^+$, такой, что $L_3 = L'_3 \times \{b\}$.

Доказательство. Выберем предложение $x \in L_2$. Так как $e \notin L_3$, то все предложения из L_3 имеют вид zb , и для завершения доказательства достаточно показать, что $b \notin L_3$. Предположим обратное: $b \in L_3$. В этом случае $L_3 \supseteq \{b, yb\}$ для некоторого $y \neq e$; и, следовательно, $L_1 \times \{b\} \supseteq \{xb, xyb\}$ и $L_1 \supseteq \{x, xy\}$, т. е. язык L_1 не является префиксным.

Лемма 2. Пусть в разделенной грамматике G для тройки цепочек x, y, φ выполняются условия $x \neq e, y \neq e, xy \in L(G, \varphi)$. Тогда существует цепочка ψ , такая, что $L(G, \psi) = x \parallel L(G, \varphi)$.

Доказательство. Рассмотрим вывод (1) предложения xy ($\varphi \equiv x_0 D_0 \beta_0$ и $xy \equiv x_n$). Обозначим через k наименьший номер $i, 0 \leq i \leq n$, для которого цепочку x_i можно представить в виде $x x'_i$. Если $k = n$, то $\psi = y$; в противном случае $\psi = x'_k D_k \beta_k$. Поскольку левый вывод любого предложения xz из $L(G, \varphi)$ (как следует из свойства 4) имеет вид $\varphi \Rightarrow^* x\psi \Rightarrow^* xz$, то $L(G, \psi) = x \parallel L(G, \varphi)$.

Следствие. Если L — разделенный язык и $xy \in L$, где $x \neq e, y \neq e$, то множество $x \parallel L$ — разделенный язык.

Лемма 3. Пусть G — разделенная грамматика и L — разделенный язык, в котором предложения z_1 и z_2 начинаются разными терминалами. Пусть для тройки φ, y и L имеют место выводы $\varphi \Rightarrow^+ yz$ для всех $z \in L$. Тогда существует цепочка $D\beta$, такая, что $\varphi \Rightarrow^+ yD\beta \Rightarrow^+ yz$ для всех $z \in L$, причем $L \subseteq L(G, D\beta)$.

Доказательство. Если $y = e$, то утверждение леммы справедливо при $D\beta = \varphi$. Пусть $y \neq e$ и z — некоторая цепочка из L . Рассмотрим вывод (1) предложения yz ($\varphi \equiv x_0 D_0 \beta_0$ и $yz \equiv x_n$). В этом выводе на некотором этапе $x_k D_k \beta_k \Rightarrow x_{k+1} D_{k+1} \beta_{k+1}$ выполняются неравенства $|x_k| < |y|$ и $|x_{k+1}| \geq |y|$. Как следует из свойства 4, применяемое на этом этапе D_k -правило зависит от символов цепочки y и не зависит от z . В частности, $x_{k+1} D_{k+1} \beta_{k+1} \Rightarrow^+ yz_1$ и $x_{k+1} D_{k+1} \beta_{k+1} \Rightarrow^+ yz_2$, а поскольку первые символы предложений z_1 и z_2 различны, то $|x_{k+1}| \leq |y|$ и, следовательно, $|x_{k+1}| = |y|, y = x_{k+1}$, т. е. утверждение леммы справедливо при $D\beta = D_{k+1} \beta_{k+1}$. Лемма доказана.

Каждую разделенную грамматику эквивалентными преобразованиями можно привести к каноническому виду, позволяющему сравнивать разделенные языки простым сравнением множеств правил вывода. Канонические грамматики должны одновременно удовлетворять шести условиям, которые удобно разбить на две группы.

3. Квазиканонические разделенные грамматики. Общие свойства различных подходов к определению канонических грамматик можно формализовать и исследовать в виде отдельного класса грамматик.

Квазиканонической разделенной грамматикой (quasicanonical separated grammar; QCS-грамматикой) называется разделенная грамматика $G = \langle N, \Sigma, P, S \rangle$, удовлетворяющая следующим условиям.

A1. Основной символ S не встречается в альтернативах правил вывода.

A2. $\forall D \rightarrow \psi \in P$ существует вывод вида $S \Rightarrow^* xD\beta \Rightarrow^* x\psi\beta \Rightarrow^* y$.

A3. $\forall A \in N'$ множество $P(A)$ содержит, по крайней мере, два правила.

A4. $\forall A \in N'$ язык $L(G, A)$ нельзя представить как $L_A \times \{a\}$, где $L_A \subseteq \Sigma^+$ и $a \in \Sigma$.

Лемма 4. 1°. Пусть G — QCS-грамматика, в которой для тройки φ, L_0 и B (где L_0 — разделенный язык) выполняется равенство $L(G, \varphi) = L_0 \times L(G, B)$. Тогда $\varphi = \eta A$ для некоторых η и A .

2°. Пусть дополнительно $\varphi = A$. Тогда каждое A -правило грамматики G имеет вид $A \rightarrow a\varphi_a C_a$, причем $L(G, a\varphi_a C_a) = L_a \times L(G, B)$, где $L_a = \{x \in L_0 : x = ax'\}$.

Доказательство. 1°. Как следует из условий A2 и A3, язык $L(G, B)$ содержит более одного предложения, поэтому φ имеет хотя бы один нетерминал и, в частности, либо $\varphi = \varphi'a$, либо $\varphi = \eta A$ для некоторых φ', a, η и A . Допустим $\varphi = \varphi'a$. Тогда $L(G, \varphi) = L_0 \times L(G, B)$, что эквивалентно $L(G, \varphi') \times \{a\} = L_0 \times L(G, B)$, и, как следует из леммы 1, $L(G, B) = L_B \times \{a\}$ для некоторого языка L_B , а это противоречит условию A4. Таким образом, для цепочки φ возможен единственный вариант: $\varphi = \eta A$.

2°. Если $\varphi = A$, то $L(G, A) = L_0 \times L(G, B)$. Выберем произвольное A -правило $A \rightarrow a\psi_a$, для которого предыдущее равенство принимает вид $L(G, a\psi_a) = L_a \times L(G, B)$. Из первой части доказательства для тройки $a\psi_a, L_a, B$ следует существование пары η_a, C_a , такой, что $a\psi_a = \eta_a C_a$, а значит η_a имеет вид $a\varphi_a$, и выбранное A -правило есть $A \rightarrow a\varphi_a C_a$.

Лемма 5. Пусть $L(G, \varphi) = L(G, \psi)$, где G — QCS-грамматика, а φ и ψ — различные цепочки. Тогда φ и ψ можно представить как $\rho_\varphi A_\varphi \mu$ и $\rho_\psi A_\psi \mu$, где A_φ и A_ψ — различные

нетерминалы, связанные одним из трех равенств: $L(G, A_\varphi) = L(G, A_\psi)$, $L(G, \varphi' A_\varphi) = L(G, A_\psi)$, $L(G, A_\varphi) = L(G, \psi' A_\psi)$ для некоторых непустых φ' и ψ' .

Доказательство. Обозначим через μ наибольший общий постфикс цепочек φ и ψ . Тогда $\varphi = \rho_\varphi X \mu$, $\psi = \rho_\psi Y \mu$, $X \neq Y$ и $L(G, \rho_\varphi X) = L(G, \rho_\psi Y) = L$. Для символов X и Y возможен один из четырех вариантов:

- 1) $X \in \Sigma$ и $Y \in \Sigma$, т. е. $L(G, \rho_\varphi a) = L(G, \rho_\psi b)$ для некоторых $a \neq b$;
- 2) $X \in \Sigma$ и $Y \in N$, т. е. $L(G, \rho_\varphi a) = L(G, \rho_\psi A_\psi)$ для некоторых a и A_ψ ;
- 3) $X \in N$ и $Y \in \Sigma$, т. е. $L(G, \rho_\varphi A_\varphi) = L(G, \rho_\psi b)$ для некоторых A_φ и b ;
- 4) $X \in N$ и $Y \in N$, т. е. $L(G, \rho_\varphi A_\varphi) = L(G, \rho_\psi A_\psi)$ для некоторых $A_\varphi \neq A_\psi$.

Вариант 1 возможен лишь при $L = \emptyset$, что противоречит условию А2. Вариант 2 при $\rho_\psi = e$ противоречит условию А4, а при $\rho_\psi \neq e$ противоречит лемме 4 (часть 1°) для тройки $\rho_\varphi a$, $L(G, \rho_\psi)$ и A_ψ . Вариант 3 также противоречит условию А4 и лемме 4 (часть 1°). Рассмотрим единственный возможный вариант 4. При $\rho_\varphi = e$ и/или $\rho_\psi = e$ доказательство леммы очевидно. Пусть $\rho_\varphi \neq e$ и $\rho_\psi \neq e$.

Зафиксируем предложение $x \in L$ и рассмотрим его выводы:

$$\begin{aligned} \rho_\varphi A_\varphi \Rightarrow^+ y_1 A_\varphi \Rightarrow^+ y_1 z_1 = x, \quad \text{причем } \rho_\varphi \Rightarrow^+ y_1, \\ \rho_\psi A_\psi \Rightarrow^+ y_2 A_\psi \Rightarrow^+ y_2 z_2 = x, \quad \text{причем } \rho_\psi \Rightarrow^+ y_2. \end{aligned}$$

Как следует из свойства 3 разделенных языков:

$$y_1 \| L = y_1 \| L(G, \rho_\varphi A_\varphi) = L(G, A_\varphi) \quad \text{и} \quad y_2 \| L = y_2 \| L(G, \rho_\psi A_\psi) = L(G, A_\psi).$$

Цепочки y_1 и y_2 являются префиксами предложения x , поэтому между ними возможно одно из трех соотношений: $y_1 = y_2$, $y_1 = y_2 y_0$ или $y_1 y_0 = y_2$, где $y_0 \neq e$.

Если $y_1 = y_2$, то $y_1 \| L = y_2 \| L$, т. е. $L(G, A_\varphi) = L(G, A_\psi)$.

Если $y_1 = y_2 y_0$, то из леммы 2 (для тройки y_2 , y_0 , ρ_φ) вытекает существование цепочки φ' , такой, что

$$y_2 \| L(G, \rho_\varphi A_\varphi) = (y_2 \| L(G, \rho_\varphi)) \times L(G, A_\varphi) = L(G, \varphi') \times L(G, A_\varphi) = L(G, \varphi' A_\varphi).$$

Из сравнения двух выражений для $y_2 \| L$ следует равенство $L(G, A_\psi) = L(G, \varphi' A_\varphi)$.

Если $y_1 y_0 = y_2$, то (аналогично соотношению $y_1 = y_2 y_0$) $L(G, A_\varphi) = L(G, \psi' A_\psi)$.

4. Канонические разделенные грамматики. Лемма 5 позволяет вполне естественно перейти к искомому каноническому представлению разделенных грамматик.

Канонической разделенной грамматикой (CS-грамматикой) называется QCS-грамматика G , удовлетворяющая следующим условиям.

А5. $L(G, A) \neq L(G, B)$ для всех $A \neq B$ из N' .

А6. $L(G, A) \neq L_0 \times L(G, B)$ для всех $A, B \in N'$ и для всех разделенных языков L_0 .

Приведенному определению не удовлетворяет QCS-грамматика \hat{g} , но удовлетворяет эквивалентная ей грамматика

$$\begin{aligned} \hat{g}: \quad S \rightarrow \quad bCA \quad | \quad cA, \quad & L(\hat{g}, S) = \{c, ba, bb\} \times L(\hat{g}, A), \\ A \rightarrow \quad a \quad | \quad bA \quad | \quad cCA, \quad & L(\hat{g}, A) = \{b, ca, cb\}^* \times \{a\}, \\ C \rightarrow \quad a \quad | \quad b, \quad & L(\hat{g}, C) = \{a, b\}. \end{aligned}$$

Алгоритмическая разрешимость задачи приведения разделенной грамматики к каноническому виду доказана, например, в [3, 4].

Теорема 1. Если $L(G, \varphi) = L(G, \psi)$ для CS-грамматики G , то $\varphi = \psi$.

Доказательство. Допустим в CS-грамматике G для некоторых $\varphi \neq \psi$ выполняется равенство $L(G, \varphi) = L(G, \psi)$. Тогда из леммы 5 следует, что в G нарушается либо условие А5, либо условие А6.

Теорема 2. Если $G = \langle N, \Sigma, P, S \rangle$ — CS-грамматика и $A \in N'$, то $L(G, A) \neq L_1 \times L_2$, для любых разделенных языков $L_1, L_2 \subseteq \Sigma^+$.

Доказательство. Допустим обратное: в некоторой CS-грамматике G существует нетерминал $A \in N'$, для которого выполняется равенство $L(G, A) = L_1 \times L_2$. Для языка L_2 возможен один из двух вариантов: либо L_2 состоит из единственного предложения xa , либо L_2 содержит не менее двух предложений. Первый случай можно исключить из рассмотрения, так как

$L(G, A) = \{yx : y \in L_1\} \times \{a\}$, что противоречит условию А4. Во втором случае, не ограничивая общности, можно полагать, что язык L_2 содержит предложения z_1 и z_2 , которые начинаются различными символами. Выберем в L_1 некоторое предложение y . Из леммы 3 (для тройки A, y, L_2) вытекает существование цепочки $B\beta$, где $\beta \in (N' \cup \Sigma)^*$, такой, что $A \Rightarrow^+ yB\beta \Rightarrow^+ yz$ для всех $z \in L_2$, причем $L_2 \subseteq L(G, B\beta)$.

Докажем равенство $L_2 = L(G, B\beta)$. Допустим, что $z \in L(G, B\beta)$. Из $A \Rightarrow^+ yB\beta$ следует утверждение $yz \in L(G, A)$. Из $L(G, A) = L_1 \times L_2$ вытекает, что $yz = y'z'$, где $y' \in L_1, z' \in L_2$. Если $y \neq y'$, то $\{y, y'\} \subseteq L_1$, что противоречит свойству 2 префиксных языков. Поэтому $y = y'$ и, следовательно, $z = z', z \in L_2$. Итак, $L(G, A) = L_1 \times L(G, B\beta)$. В зависимости от самого правого символа цепочки $B\beta$ последнее равенство противоречит либо условию А4, либо условию А6.

5. Первый характеристический признак CS -грамматик. Этот признак позволяет для идентификации канонических разделенных грамматик использовать альтернативную формулировку условия А6, опирающуюся на одно структурное свойство нетерминалов.

Пусть $G = \langle N, \Sigma, P, S \rangle$ — разделенная грамматика и X — фиксированный символ из $N' \cup \Sigma$. Обозначим через $RD(G, X)$ совокупность непустых подмножеств $N_X \subseteq N'$, таких, что $X \notin N_X$, а все правила из $\hat{P}(N_X)$ имеют вид $A \rightarrow \varphi Y$, где $Y = X$ либо $Y \in N_X$. Заметим, что А4 эквивалентно условию “ $R(D, a) = \emptyset$ для всех $a \in \Sigma$ ”. Будем рассматривать грамматики, удовлетворяющие условию

А6'. $RD(G, A) = \emptyset$ для всех $A \in N'$.

Теорема 3. Если QCS -грамматика G удовлетворяет условиям А5 и А6', то G является CS -грамматикой.

Доказательство. Предположим, что в QCS -грамматике G , удовлетворяющей условиям теоремы, не выполняется условие А6, т.е. существуют несколько пар A_i, B_i , для которых $L(G, A_i) = L_{A_i B_i} \times L(G, B_i)$, где $L_{A_i B_i}$ — разделенные языки. Покажем, что такое предположение противоречит условию А6'.

Обозначим через $h(A)$ длину самого короткого предложения языка $L(G, A)$. Из пар A_i, B_i выберем пару A_m, B_m с наименьшим значением $h(B_i)$. Для этой пары определим непустое множество нетерминалов N_{B_m} :

$$N_{B_m} \stackrel{\text{def}}{=} \{A \in N' : L(G, A) = L_{AB_m} \times L(G, B_m)\},$$

и покажем, что $N_{B_m} \in RD(G, B_m)$.

Для некоторого $A \in N_{B_m}$ выберем произвольное A -правило. Как следует из леммы 4 (часть 2) (для тройки A, L_{AB_m} и B_m), выбранное правило имеет вид $A \rightarrow a\rho_a C_a$, причем $L(G, a\rho_a C_a) = L_a \times L(G, B_m)$, где L_a — подмножество предложений из L_{AB_m} , начинающихся терминалом a . В языке $L_0 = L(G, a\rho_a) \times L(G, C_a) = L_a \times L(G, B_m)$ выберем некоторое предложение $x \in L_0$, которое можно представить как $x = y_1 z_1 = y_2 z_2$, где $y_1 \in L(G, a\rho_a), y_2 \in L_a$. Из свойства 3 разделенных языков следует, что $y_1 \parallel L_0 = L(G, C_a)$ и $y_2 \parallel L_0 = L(G, B_m)$. Цепочки y_1 и y_2 являются префиксами предложения x , поэтому между ними возможно одно из трех соотношений: $y_1 = y_2, y_1 y_0 = y_2$ или $y_1 = y_2 y_0$, где $y_0 \neq \epsilon$.

Если $y_1 = y_2$, то $y_1 \parallel L_0 = y_2 \parallel L_0, L(G, C_a) = L(G, B_m)$ и, как следует из условия А5, $C_a = B_m$.

Если $y_1 y_0 = y_2$, то $L(G, C_a) = y_1 \parallel L_0 = (y_1 \parallel L_a) \times L(G, B_m) = L'_a \times L(G, B_m)$, где L'_a — некоторый разделенный язык, существующий в силу леммы 2, т.е. $C_a \in N_{B_m}$.

Если $y_1 = y_2 y_0$, то $L(G, B_m) = y_2 \parallel L_0 = L''_a \times L(G, C_a)$, где $L''_a = y_2 \parallel L(G, a\rho_a)$ — разделенный язык, существующий в силу леммы 2, т.е. $h(B_m) > h(C_a)$, что противоречит выбору B_m .

Итак, для $A \in N_{B_m}$ произвольное A -правило имеет вид $A \rightarrow a\rho_a C_a$, причем $C_a = B_m$ либо $C_a \in N_{B_m}$, что означает $B_m \in RD(G, B_m)$.

6. Второй характеристический признак CS -грамматик. Этот признак позволяет для идентификации канонических разделенных грамматик использовать альтернативную формулировку условия А5. Следуя [5], введем на множестве нетерминалов отношение структурной эквивалентности.

Пусть $G = \langle N, \Sigma, P, S \rangle$ — грамматика и E — бинарное отношение на некотором подмножестве нетерминалов N' . Обозначим символом $\underset{E}{\simeq}$ отношение эквивалентности, полученное из E посредством рефлексивного и транзитивного замыкания отношения $E \cup \{(D, D) : D \in N'\}$. Доопределим

отношение $\underset{E}{\simeq}$ на множество цепочек следующим образом:

$$\alpha_0 A_1 \alpha_1 \dots A_n \alpha_n \underset{E}{\simeq} \alpha_0 B_1 \alpha_1 \dots B_n \alpha_n \Leftrightarrow \left(A_i \underset{E}{\simeq} B_i \text{ для } i = 1, \dots, n \right).$$

Отношение $\underset{E}{\simeq}$ будем называть *отношением структурной эквивалентности* и обозначать его $\underset{E}{\approx}$, если из $A \underset{E}{\simeq} B$ следует, что для любого правила $A \rightarrow \varphi$ существует правило $B \rightarrow \psi$, для которого $\varphi \underset{E}{\simeq} \psi$. Отношение $\underset{E}{\approx}$ будем называть *тривиальным*, если из $A \underset{E}{\approx} B$ следует $A = B$. Известно, что из $A \underset{E}{\approx} B$ следует $L(G, A) = L(G, B)$. Будем рассматривать грамматики, удовлетворяющие условию

A5'. Все отношения структурной эквивалентности на N' тривиальны.

Теорема 4. Если QCS-грамматика G удовлетворяет условиям A5' и A6, то G является CS-грамматикой.

Доказательство. Пусть G — QCS-грамматика, удовлетворяющая условиям теоремы 4. Обозначим через E множество пар различных нетерминалов (A, B) , для которых $L(G, A) = L(G, B)$. Докажем, что $E = \emptyset$, что эквивалентно условию A5.

Предположим, что $E \neq \emptyset$, т. е. $L(G, A) = L(G, B)$ для некоторых $A \neq B$. Поскольку G — QCS-грамматика, то любому A -правилу $A \rightarrow a\eta$ можно взаимно однозначно сопоставить B -правило $B \rightarrow a\rho$, причем $L(G, a\eta) = L(G, a\rho)$.

Равенство $L(G, a\eta) = L(G, a\rho)$ возможно либо при $a\eta = a\rho$, либо при $a\eta \neq a\rho$. В первом случае соотношение $a\eta \underset{E}{\approx} a\rho$ очевидно. Во втором случае из леммы 5 для цепочек $a\eta$ и $a\rho$ следует, что $a\eta = a\eta_1 A_1 \mu_0$ и $a\rho = a\rho_1 B_1 \mu_0$, причем для пары различных нетерминалов A_1 и B_1 возможно одно из трех: либо $L(G, A_1) = L(G, B_1)$, либо $L(G, A_1) = L(G, \psi' B_1)$, либо $L(G, \psi' A_1) = L(G, B_1)$. Второе и третье равенства противоречат условию A6, а из первого равенства следует: $(A_1, B_1) \in E$ и $L(G, a\eta_1) = L(G, a\rho_1)$.

Равенство $L(G, a\eta_1) = L(G, a\rho_1)$ рассматривается аналогично, оно возможно либо при $a\eta_1 = a\rho_1$, либо при $a\eta_1 = a\eta_2 A_2 \mu_1$ и $a\rho_1 = a\rho_2 B_2 \mu_1$, где $(A_2, B_2) \in E$ и $L(G, a\eta_2) = L(G, a\rho_2)$.

Генерация пар $a\eta_i$ и $a\rho_i$ не может быть бесконечной, поскольку $|\eta_1|, |\eta_2|, \dots$ есть монотонно убывающая последовательность. На некотором n -м этапе будут получены представления цепочек $a\eta$ и $a\rho$ в виде $a\eta_n A_n \mu_{n-1} \dots A_1 \mu_0$ и $a\eta_n B_n \mu_{n-1} \dots B_1 \mu_0$, причем $\{(A_n, B_n), \dots, (A_1, B_1)\} \subseteq E$, т. е. $a\eta \underset{E}{\approx} a\rho$ и $\underset{E}{\approx}$ есть нетривиальное отношение структурной эквивалентности, что противоречит условию A5'.

7. Единственность CS-грамматик. В каждом классе эквивалентности разделенных грамматик существует ровно одна унифицированная каноническая грамматика. Это утверждение устанавливается в два приема: сначала доказывается, что эквивалентные CS-грамматики совпадают с точностью до переименования нетерминалов, а затем излагается метод унификации алфавита нетерминальных символов. Здесь и далее под переименованием понимается применение некоторого взаимно однозначного отображения.

Теорема 5. Пусть $G_1 = \langle N_1, \Sigma_1, P_1, S_1 \rangle$ и $G_2 = \langle N_2, \Sigma_2, P_2, S_2 \rangle$ — эквивалентные CS-грамматики, в которых $S_1 \neq S_2$ и $A \in N'_1 \cap N'_2 \Leftrightarrow L(G_1, A) = L(G_2, A)$. Тогда $N'_1 = N'_2$, $R(G_1, S_1) = R(G_2, S_2)$ и $\widehat{P}_1(N'_1) = \widehat{P}_2(N'_2)$.

Доказательство. Обозначим: $\Delta_1 = N'_1 \setminus N'_2$ и $\Delta_2 = N'_2 \setminus N'_1$. Выберем не встречающиеся в G_1 и G_2 символы $+$, \div и S .

Часть I. Построим грамматику $G = \langle N, \Sigma, P, S \rangle$ следующим образом:

$$\begin{aligned} N &= \{S\} \cup N_1 \cup N_2 \equiv \{S\} \cup \{S_1, S_2\} \cup N'_1 \cup \Delta_2, & \Sigma &= \{+, \div\} \cup \Sigma_1, \\ P &= \{S \rightarrow + S_1, S_1 \rightarrow +\} \cup P(S_1) \cup \widehat{P}_1(N'_1) \cup \\ &\cup \{S \rightarrow \div S_2, S_2 \rightarrow \div\} \cup P(S_2) \cup \widehat{P}_2(\Delta_2). \end{aligned}$$

По построению для нетерминалов из N' справедливы равенства:

$$\begin{aligned} L(G, S_1) &= L(G_1, S_1) \cup \{+\}, & L(G, A) &= L(G_1, A) \text{ для всех } A \in N'_1, \\ L(G, S_2) &= L(G_2, S_2) \cup \{\div\}, & L(G, B) &= L(G_2, B) \text{ для всех } B \in \Delta_2. \end{aligned} \tag{2}$$

Часть II. Покажем, что G — CS -грамматика. Условия А1, А2 и А3 вытекают из определения G , условие А4 следует из равенств (1). Условие А5 подтверждается следующими выкладками:

$$\begin{aligned} L(G, S_1) &\neq L(G_1, S_2), & L(G, A) &\neq L(G, B) \text{ для всех различных } A, B \in N'_1 \cup \Delta_2, \\ L(G, S_1) &\neq L(G, C), & L(G, S_2) &\neq L(G, C) \text{ для всех } C \in N'_1 \cup \Delta_2. \end{aligned}$$

Остановимся на проверке условия А6. Соответствующие неравенства с участием S_1 и S_2 следуют (для любых L_0 и $A \in N'_1 \cup \Delta_2$) из уникальности терминалов \div и $+$:

$$\begin{aligned} L(G, S_1) &\neq L_0 \times L(G, S_2), & L(G, S_2) &\neq L_0 \times L(G, S_1), \\ L(G, S_i) &\neq L_0 \times L(G, A_i), & L(G, A_i) &\neq L_0 \times L(G, S_i), \quad i=1, 2. \end{aligned}$$

Таким образом, проверка условия А6 сводится к доказательству неравенства $L(G, A) \neq L_0 \times L(G, B)$ для всех L_0 и $A \neq B$ из $N_1 \cup \Delta_2$. Предположим обратное: $L(G, A) = L_0 \times L(G, B)$ для некоторых L_0 и $A \neq B$. Нетерминал A является символом алфавита N_i , $i = 1$ или $i = 2$, поэтому $L(G_i, A) = L_0 \times L(G, B)$, что противоречит теореме 2, так как G_i — CS -грамматика, а L_0 и $L(G, B)$ — разделенные языки (см. свойство 1 разделенных грамматик).

Часть III. Покажем справедливость равенства $R(G_1, S_1) = R(G_2, S_2)$. Пусть $a\eta \in R(G_1, S_1)$. Из эквивалентности G_1 и G_2 следует, что в $R(G_2, S_2)$ существует цепочка $a\rho$, начинающаяся тем же терминалом a . По построению в грамматике G имеются правила $S_1 \rightarrow a\eta$ и $S_2 \rightarrow a\rho$, причем $L(G, a\eta) = L(G, a\rho)$, и, как следует из теоремы 1, $a\eta = a\rho$.

Часть IV. Покажем, что выполняются равенства $N'_1 = N'_2$ и $L(G_1, \varphi) = L(G_2, \varphi)$ для любой цепочки $\varphi \in (N'_1 \cup \Sigma)^+$. Рассмотрим произвольное предложение $a\alpha$ из $L(G, S_2) \setminus \{\div\} \equiv L(G_2, S_2)$ и его вывод в грамматике G : $S_2 \Rightarrow_G a\rho \Rightarrow_G^* a\alpha$. Как следует из части III настоящего доказательства, цепочка ρ не содержит символы из N_2 , а поскольку $P_1 \subset P$, то в выводе предложения $a\alpha$ не участвуют нетерминалы Δ_2 . Так как грамматика G удовлетворяет условию А2, то $\Delta_2 = \emptyset$. Аналогично доказывается $\Delta_1 = \emptyset$. Из $N'_1 = N'_2$ следует, что $L(G_1, A) = L(G_2, A)$ для всех $A \in N'_1$ и поэтому

$$\begin{aligned} L(G_1, \varphi) &= L(G_1, x_0 A_1 x_1 \dots A_k x_k) = \{x_0\} \times L(G_1, A_1) \times \dots \times L(G_1, A_k) \times \{x_k\} \\ &= \{x_0\} \times L(G_2, A_1) \times \dots \times L(G_2, A_k) \times \{x_k\} = L(G_2, \varphi). \end{aligned}$$

Часть V. Покажем, что $\widehat{P}_1(N'_1) = \widehat{P}_2(N'_2)$. Предположим, что в G_1 и G_2 существуют правила $A \rightarrow a\eta$ и $A \rightarrow a\rho$, в которых $a\eta \neq a\rho$, но $L(G_1, a\eta) = L(G_2, a\rho)$. Как доказано в части IV $L(G_1, a\eta) = L(G_2, a\eta)$, т. е. в CS -грамматике G_2 существуют различные цепочки $a\eta$ и $a\rho$, для которых $L(G_2, a\eta) = L(G_2, a\rho)$, что противоречит теореме 1.

Следствие. Пусть $G_1 = \langle N_1, \Sigma, P_1, S \rangle$ и $G_2 = \langle N_2, \Sigma, P_2, S \rangle$ две эквивалентные CS -грамматики, в которых $D \in N_1 \cap N_2 \Leftrightarrow L(G_1, D) = L(G_2, D)$. Тогда $N_1 = N_2$ и $P_1 = P_2$.

Пусть $G_{\text{fix}} = \langle N, \Sigma, P, S \rangle$ — разделенная грамматика, удовлетворяющая условию А2, и Γ — символ, не встречающийся в G_{fix} . Сопоставим грамматике G_{fix} эквивалентную ей *унифицированную* грамматику $\overline{G}_{\text{fix}} = \langle \overline{N}, \Sigma, \overline{P}, \Gamma_\emptyset \rangle$, в которой каждый нетерминал D переименован в $\Gamma_{\overline{D}}$, где \overline{D} — специально построенное множество, исполняющее роль индекса при Γ .

Для вычисления индексов \overline{D} используется ориентированный граф $\langle N, W \rangle$, помеченные дуги которого порождаются правилами грамматики G_{fix} :

$$(D, B)_{a_m} \in W \Leftrightarrow (D \rightarrow a\mu B\eta \in P \quad \& \quad m = |a\mu B|);$$

метка a_m определяется первым символом альтернативы D -правила и позицией нетерминала B в этой альтернативе. Переименования нетерминалов в грамматике G_{fix} порождают графы, изоморфные $\langle N, W \rangle$, причем в этих графах сохраняется разметка ребер. Смежность вершин и разметка ребер в графах, изоморфных $\langle N, W \rangle$, однозначно определяют позиции нетерминалов в правилах вывода, а также задают группы позиций, отвечающих каждому нетерминалу.

В графе $\langle N, W \rangle$ для каждого нетерминала D существует путь от вершины S к вершине D . Последовательность меток, расположенных на дугах этого пути, образует D -фразу; длина D -фразы измеряется количеством дуг. По определению индекс \overline{D} есть совокупность всех D -фраз, длина которых не превосходит $\max\{w(D') : D' \in N\} + 1$, где $w(D')$ — минимальная длина D' -фраз. В случае $G_{\text{fix}} = \widehat{g}$ (см. п. 6) унифицированная грамматика $\overline{G}_{\text{fix}}$ получается так:

$$N = \{S, A, C\}; \quad W = \{(S, C)_{b_2}, (S, A)_{c_2}, (S, A)_{b_3}, (A, A)_{b_2}, (A, C)_{c_2}, (A, A)_{c_3}\};$$

$$w(S) = 0, w(A) = 1, w(C) = 1; \quad \max\{0, 1, 1\} + 1 = 2;$$

$$\overline{S} = \emptyset, \quad \overline{A} = \{b_3, c_2, b_3 b_2, b_3 c_3, c_2 b_2, c_2 c_3\}, \quad \overline{C} = \{b_2, b_3 c_2, c_2 c_2\};$$

$$\overline{G}_{\text{fix}}: \Gamma_\emptyset \rightarrow b\overline{\Gamma}_C \overline{\Gamma}_A | c\overline{\Gamma}_A, \quad \overline{\Gamma}_A \rightarrow a | b\overline{\Gamma}_A | c\overline{\Gamma}_C \overline{\Gamma}_B, \quad \overline{\Gamma}_C \rightarrow a | b.$$

Множество индексов $\overline{N} = \{\overline{D}: D \in N\}$ позволяет построить следующий граф $\langle \overline{N}, \overline{W} \rangle$, изоморфный $\langle N, W \rangle$:

$$(\overline{D}, \overline{B})_{a_i} \in \overline{W} \Leftrightarrow \exists x (x \in \overline{D} \ \& \ x a_i \in \overline{B}).$$

Поэтому CS-грамматики эквивалентны тогда и только тогда, когда они преобразуются в одну и ту же унифицированную грамматику \overline{G} .

8. Заключительные замечания. В связи с теоремой 1 возникает вопрос о существовании разделенных грамматик, для которых из $L(G, \varphi) \supseteq L(G, \psi)$ следует $\varphi \Rightarrow^* \psi$. Далее, в формулировках теорем 1 и 4 условие A6 может быть ослаблено, а именно, достаточно предположить, что L_0 является производным языком заданной QCS-грамматики. И наконец, как следует из теорем 3 и 4, наиболее сложные для проверки условия A5 и A6 можно изменять по отдельности, но не одновременно (см. грамматику \hat{g}); вопрос о дополнительном условии, гарантирующем совместно с A5' и A6' каноничность QCS-грамматик, остается открытым.

СПИСОК ЛИТЕРАТУРЫ

1. Courcelle B. Une forme canonique pour les grammaires simples deterministes // RAIRO — Theoretical Informatics and Applications. 1974. **8.R1**. P. 19–36.
2. Ахо А., Ульман Дж. Теория синтаксического анализа, перевода и компиляции. Т. 1. М.: Мир, 1978.
3. Серебряков В.А., Соловьев С.Ю. Задача совместимости свойств формальных грамматик // Информационные процессы. 2012. **12**. № 4. С. 408–437.
4. Bastien C., Czyzowicz J., Fraczak W., Rytter W. Prime normal form and equivalence of simple grammars // Implementation and Application of Automata. Lecture Notes in Computer Science. Vol. 3845. Berlin: Springer, 2006. P. 78–89.
5. Paull M.C., Unger S.H. Structural equivalence of context-free grammars // J. Computer and System Sci. 1968. **2**. P. 427–463.

Поступила в редакцию
16.09.15

SINGULARITIES OF CANONICAL SEPARATED GRAMMARS

Soloviev S. Y.

Class canonical separated grammars that generate the same language as the general separated grammar are considered. We present the basic properties and two criterion of canonical grammars. We propose a method of nonterminals unification and prove the uniqueness of the canonical representation separated grammar.

Keywords: separated grammars, uniqueness.