

Алгоритм преобразования бесконтекстных выражений в эквивалентные L-графы

Му Цзиньюань

Аннотация—Рассматриваются бесконтекстные грамматики и их альтернативные представления — а именно, бесконтекстные выражения и бесконтекстные L-графы. Бесконтекстное выражение, по сути, является алгебраической формой представления бесконтекстных грамматик: оно не уступает известным методам в лаконичности, но при этом более подробно и наглядно показывает, как цепочки языка порождаются из подчиненных цепочек. Что касается бесконтекстного L-графа, то он представляет собой ориентированный граф, на дугах которого расположены пометки — символы из алфавита основных символов и дополнительные скобочные метки, влияющие на успешность прохождения пути из начальной вершины в заключительную (требуется сбалансированность скобок).

В настоящей статье основное внимание уделяется алгоритму преобразования контекстно-свободных выражений в эквивалентные L-графы. Предлагаемый алгоритм сопровождается доказательством корректности и включает идею удаления избыточных вершин. Такой синтез алгебраического и графического подходов объединяет их ключевые преимущества: с одной стороны, бесконтекстные выражения обеспечивают компактность и ясность описания, а с другой — бесконтекстные L-графы наглядно визуализируют структуру языка. Такой комбинированный подход создает предпосылки для разработки более эффективных инструментов анализа и преобразования языковых описаний в компиляторах и системах обработки текста.

Ключевые слова—бесконтекстное выражение, обобщение регулярного выражения, контекстно-свободная грамматика, бесконтекстный L-граф.

I. ВВЕДЕНИЕ

Понятие бесконтекстной (контекстно-свободной) грамматики занимает центральное место во многих разделах теоретической информатики и лежит в основе таких процессов, как компиляция и ассемблирование, а также находит применение в решении задач искусственного интеллекта и проектировании аппаратного обеспечения вычислительных систем.

Бесконтекстные грамматики достаточно выразительны, чтобы представлять синтаксис большинства языков программирования, и почти все современные языки программирования описываются бесконтекстными грамматиками. С другой стороны, эти грамматики достаточно просты, чтобы алгоритмы синтаксического анализа для них были эффективны, причём некоторые из таких алгоритмов имеют линейную сложность для распознавания принадлежности цепочки языку, порождаемому грамматикой [1], [2], [3].

Альтернативой описанию языков с помощью бесконтекстных грамматик являются бесконтекстные выражения, введённые Л. И. Станевичем в [4], [5], и бесконтекстные L-графы, предложенные в [6]. Бесконтекстные выражения как алгебраическая форма представления более удобны для задания формального языка в программе в виде текстового описания. Более того, такая форма сохраняет лаконичность описательного метода и нагляднее демонстрирует закономерности генерации цепочек языка из подчинённых строк. L-графы предоставляют более интуитивно понятное графическое представление для бесконтекстных языков. Применение методов теории графов позволяет значительно повысить модульность обработки языковых описаний.

В работе предлагается алгоритм преобразования бесконтекстных выражений в соответствующие L-графы и доказывается их эквивалентность. Это позволяет обобщить известный подход для поиска строк по регулярным выражениям, реализованным с помощью конечных автоматов, на случай бесконтекстных языков.

II. ОПИСАНИЕ БЕСКОНТЕКСТНОГО ЯЗЫКА

A. Бесконтекстное выражение

Бесконтекстные выражения (по-другому: контекстно-свободные выражения, кратко — КС-выражения) характеризуют класс бесконтекстных (контекстно-свободных) языков. То есть любое бесконтекстное выражение задаёт некоторый бесконтекстный язык, и наоборот — любой бесконтекстный язык может быть задан бесконтекстным выражением.

В данном разделе на основе понятий, предложенных Л. И. Станевичем в [5], приводится модификация бесконтекстных выражений с добавлением конструкций, явно описывающих итерацию как в регулярных языках, классифицируются виды скобок в составе бесконтекстного выражения, и определяются их свойства и назначение.

Для определения КС-выражений часто используют операцию именованного, имеющую два операнда: имя из некоторого конечного множества и выражение, которому это имя сопоставляется. Использование именованных подвыражений позволяет удобно размножать вхождения некоторых подцепочек в цепочку языка. Количество используемых в выражении имен может зависеть от конкретного языка. Операцию именованного можно выразить с помощью скобок, окаймляющих операнд выражения скобками $\langle \iota$ и $\rangle_\iota$, где ι — операнд.

Определение 1: Пусть $Names$ — непустое конечное множество, содержащее операнды, $\mathcal{B}$ — множество именованного КС-выражения, состоящее из операнд ι и скобок,

$\mathcal{B} = \{<_{\iota}, >_{\iota} \mid \iota \in Names\}$. Пусть множества Σ , $\mathcal{B}$ и $\{+, \varepsilon, \emptyset, (,), [,]\}$ попарно не пересекаются, $\mathcal{A} = \Sigma \cup \mathcal{B} \cup \{+, \varepsilon, \emptyset, (,), [,]\}$. Определим рекурсивно КС-выражение над алфавитом Σ (это элементарные символы в алфавите $\mathcal{A}$):

- 1) $a \in \Sigma \cup \{\varepsilon, \emptyset\}$ — КС-выражение;
- 2) если α и β — КС-выражения, то:
 - а) $\alpha + \beta$ — КС-выражение; подвыражения α и β данного выражения будем называть его *слагаемыми*, само выражение — *суммой*;
 - б) $(\alpha)(\beta)$ — КС-выражение; подвыражения α и β выражения $(\alpha)(\beta)$ будем называть его *сомножителями*; заключать сомножитель в круглые скобки не обязательно, если он не является суммой;
- 3) если $\iota \in Names$, α , β и γ — КС-выражения, то $<_{\iota}(\alpha)\beta(\gamma)>_{\iota}$ есть КС-выражение, или ι -гнездо; имени ι сопоставляются подвыражения α и γ ;
- 4) если α — КС-выражение, то $[\alpha]$ есть КС-выражение.

Следующие вспомогательные понятия помогают определить язык, задаваемый КС-выражением.

Определение 2: Назовем *фракцией* КС-выражения над алфавитом Σ элемент следующего рекурсивно определяемого множества КС-выражений:

- 1) $Fractions(a) = \{a\}$ для $a \in \Sigma \cup \{\varepsilon, \emptyset\}$;
- 2) если α , β и γ суть КС-выражения, то

$$Fractions((\beta)) = Fractions(\beta),$$

$$Fractions(\alpha + \beta) = Fractions(\alpha) \cup Fractions(\beta),$$

$$Fractions((\alpha)(\beta)) = Fractions(\alpha)Fractions(\beta),$$

$$Fractions(<_{\iota}(\alpha)\beta(\gamma)>_{\iota}) =$$

$$\{<_{\iota}\{Fractions(\alpha)\}\{Fractions(\beta)\}\{Fractions(\gamma)\}\}>_{\iota},$$

$$Fractions([\beta]) = \{[\beta]Fractions(\beta)\}.$$

Из определения фракции следует, что она представляет собой КС-выражение, не содержащее сумм и круглых скобок, порожденных операцией произведения. В состав фракций входят неразложимые слагаемые. Будем называть фракцией каждый элемент определяемого далее клана КС-выражения.

Пример 1: Рассмотрим КС-выражения $\zeta =$

$$<_1(a+b)[b](c)>_1(c+d)((a+b)(c+d)).$$

Разделим КС-выражение ζ на подвыражения по сомножителям

$$\overbrace{<_1(a+b)[b](c)>_1(c+d)((a+b)(c+d))}^{\text{Произведение с 3 сомножителями}}$$

$\underbrace{<_1(a+b)[b](c)>_1}_{\iota\text{-гнездо}} \underbrace{(c+d)}_{\text{сомножитель}} \underbrace{((a+b)(c+d))}_{\text{сомножитель}}$

$$Fractions(\zeta) = Fractions(<_1(a+b)[b](c)>_1)Fractions(c+d)Fractions((a+b)(c+d)).$$

Вычислим фракции для каждого подвыражения:

- 1) $Fractions(<_1(a+b)[b](c)>_1) = \{<_1(a)[b](c)>_1, <_1(b)[b](c)>_1\}$;
- 2) $Fractions(c+d) = \{c, d\}$;
- 3) $Fractions((a+b)(c+d)) = \{ac, ad, bc, bd\}$.

Объединяем результаты $Fractions(\zeta) = \{<_1(a)[b](c)>_1, <_1(b)[b](c)>_1\}\{c, d\}\{ac, ad, bc, bd\}$. В итоговом множестве фракции содержится 16 элементов.

Введем Λ для обозначения пустой цепочки, тогда как ε в этой статье будет встречаться как символ алфавита, из которого составляются регулярные и бесконтекстные выражения.

Определение 3: Пусть α , β и γ — фракции. Для КС-выражения ζ , над алфавитом Σ определим его *пометку* следующим образом:

$$\omega(\zeta) = \begin{cases} \{a\}, \zeta = a \in \Sigma; \\ \{\Lambda\}, \zeta = \varepsilon \in \Sigma; \\ \emptyset, \zeta = \emptyset; \\ \omega(\alpha)\omega(\beta), \zeta = \alpha\beta; \\ \omega(\alpha)\omega(\beta)\omega(\gamma), \zeta = <_{\iota}(\alpha)\beta(\gamma)>_{\iota}; \\ \omega(\beta), \zeta = [\beta]. \end{cases} \quad (2)$$

Определение 4: Клан, порождаемый КС-выражением ζ , определим рекурсивно:

$$Clan(\zeta) = Trim(Fractions(\zeta)) \cup \{\beta_1 S \beta_3 \mid \alpha_1 S \alpha_3, \beta_1 S' \beta_3 \in Clan(\zeta), S = <_{\iota}(\gamma)\alpha_2(\gamma')>_{\iota} \text{ или } [\alpha_2], S' = <_{\iota}(\gamma)\beta_2(\gamma')>_{\iota} \text{ или } [\beta_2]\}. \quad (3)$$

Результат *приведения* некоторого КС-выражения ζ обозначим через $Trim(\zeta)$ (см. [5]). Цель приведения КС-выражения заключается в том, чтобы получить эквивалентное КС-выражение, которое имеет более простую структуру и не содержит ненужных элементов, таких как пустые скобки и ненужные гнезда.

Согласно определению клана, клан КС-выражения может не совпадать с множеством его приведённых фракций в случае наличия в КС-выражении нескольких подвыражений с одинаковыми именами. Это объясняется тем, что при формировании клана любое именованное подвыражение может быть заменено любым другим подвыражением с тем же именем. Данная замена реализует механизм разрастания языковых цепочек.

Определение 5: Язык, задаваемый КС-выражением ζ , есть подмножество множества Σ^* :

$$L(\zeta) = \bigcup_{\xi \in Clan(\zeta)} \omega(\xi). \quad (4)$$

Язык пуст, если пуст клан.

В. Классификация скобок в КС-выражениях

В КС-выражениях скобочная система определяется с помощью множества именованных и квадратных скобок, а также проекции *projection* (см. [5]), возвращающей цепочку, которая состоит исключительно из скобок, принадлежащих заданному подмножеству множества именованных и квадратных скобок.

Определение 6: Пусть ζ — некоторое КС-выражение и для любого подмножества B алфавита скобок $\mathcal{B} \cup \{[,]\}$ цепочка *projection*(ζ, B) является *скобочной системой*.

В алфавите $\mathcal{A}$, помимо множества именованных КС-выражений B (угловых скобок), существуют ещё два типа скобок: круглые скобки $\{(\cdot), (\cdot)\}$ и квадратные скобки $\{[\cdot], [\cdot]\}$. Далее приведём правила порождения языка, задаваемые скобками в КС-выражениях.

- 1) угловые скобки — подцепочки с угловыми скобками, называемые *парными друг другу циклами*, левым и правым соответственно. Для КС-выражения $\zeta = \langle_{\iota}(\alpha)\gamma(\beta)\rangle_{\iota}$, где α , β и γ — КС-выражения, то подцепочки $\langle_{\iota}(\alpha)$ и $(\beta)\rangle_{\iota}$ назовем его *парными циклами*;
- 2) квадратные скобки — подцепочки в квадратных скобках могут *повторяться любое число раз* (это особый вид скобок, добавленный к бесконтекстным выражениям, эти скобки являются аналогом операции звезды Клини в регулярных выражениях). Для КС-выражения $\zeta = \alpha[\gamma]\beta$, где α , β и γ — КС-выражения, то подцепочки $[\gamma]$ назовем его *нейтральными циклами*;
- 3) круглые скобки — подцепочки в круглых скобках обычно представляют собой либо форму суммы, либо КС-выражения, явно сопоставленные именovanым скобкам (угловым скобкам).

С. Глубина, ширина и ядро КС-выражения

Цепочка w принадлежит языку $\mathcal{L}_P$ (см. [7]), если все скобки в ней сбалансированы.

Определение 7: Пусть ζ — КС-выражение и скобочная система P представляет собой проекцию $projection(\zeta, B)$. Назовем ι -глубиной КС-выражения ζ число $depth_{\iota}(P)$, определяемое рекурсивно:

- 1) $depth_{\iota}(\Lambda) = 0$;
- 2) $depth_{\iota}(P) = depth_{\iota}(P') + 1$, $P = \langle_{\iota}P'\rangle_{\iota}$, $P' \in \mathcal{L}_P$;
- 3) $depth_{\iota}(P) = \max(depth_{\iota}(P_1), depth_{\iota}(P_2))$, $P = P_1P_2$, $P_1, P_2 \in \mathcal{L}_P$.

Определение 8: Назовем *глубиной* КС-выражения ζ число

$$depth(\zeta) = \max\{depth_{\iota}(P) \mid P = projection(\zeta, B)\}. \quad (5)$$

Для КС-выражения ζ определим его проекцию K как $projection(\zeta, B \cup \{[,]\})$, которая возвращает цепочку, состоящую исключительно из элементов угловых скобок и квадратных скобок. Протяжение определяется как число делений для проекции K , при котором угловые скобки и квадратные скобки сохраняют сбалансированность после делений.

Определение 9: Назовем *протяжением* скобочной системы K число $parti(K)$, определяемое рекурсивно:

- 1) $parti(\Lambda) = 0$;
- 2) $parti(K) = 1$, $K = [K']$ или $K = \langle_{\iota}K'\rangle_{\iota}$, $K' \in \mathcal{L}_P$;
- 3) $parti(K) = parti(K_1) + parti(K_2)$, $K = K_1K_2$, $K_1, K_2 \in \mathcal{L}_P$.

Определение 10: Назовем *шириной* КС-выражения ζ число

$$\begin{aligned} width(\zeta) = \max\{parti(K') \mid K = \\ projection(\zeta, B \cup \{[,]\}), \\ K = K_1K'K_2, \text{ для некоторых фрагментов} \\ K_1 \text{ и } K_2, K' \in \mathcal{L}_P\}. \end{aligned} \quad (6)$$

Определение 11: Пусть $d > 0$. Назовем d -ядром КС-выражения ζ и обозначим через $Core(\zeta, d)$ подмно-

жество всех элементов его клана, высота которых не превосходит d :

$$Core(\zeta, d) = \{\xi \in Clan(\zeta) \mid depth(\xi) \leq d\}. \quad (7)$$

Пример 2: Рассмотрим КС-выражение $\zeta =$

$$x[a]y[\langle_{\iota} \langle_{\iota}(a)\langle_{\iota}(a)b(a)\rangle_{\iota} \rangle_{\iota} \rangle_{\iota} [b] \langle_{\iota}(c)d(a+c)\rangle_{\iota} \rangle_{\iota}$$

Получаем следующие скобочные системы P :

- 1) $projection(\zeta, P_1) = \langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota} \rangle_{\iota}$ с глубиной $depth_1(P_1) = 2$, где $P_1 = \{\langle_{\iota}, \rangle_{\iota}\}$;
- 2) $projection(\zeta, P_2) = \langle_{\iota} \rangle_{\iota} \rangle_{\iota}$ с глубиной $depth_2(P_2) = 1$, где $P_2 = \{\langle_{\iota}, \rangle_{\iota}\}$.

Таким образом, глубина КС-выражения ζ равна $depth(\zeta) = 2$.

Рассмотрим теперь скобочные системы K : $projection(\zeta, B \cup \{[,]\}) = [\langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota} [\langle_{\iota} \rangle_{\iota}] \langle_{\iota} \rangle_{\iota}$ с протяжением $parti(K) = 2$ (то есть она может быть разделена на две цепочки: $[\langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota}$ и $[\langle_{\iota} \rangle_{\iota}] \langle_{\iota} \rangle_{\iota}$). Чтобы получить ширину, необходимо найти все возможные протяжения и взять максимальное. В данном случае наблюдаем, что внутри цепочки $[\langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota} [\langle_{\iota} \rangle_{\iota}] \langle_{\iota} \rangle_{\iota}$ присутствует делимая на часть подцепочка $[\langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota} [\langle_{\iota} \rangle_{\iota}] \langle_{\iota} \rangle_{\iota}$ (обозначим её K'), для которой $parti(K') = 3$. Затем переходим к подцепочке $\langle_{\iota} \langle_{\iota} \langle_{\iota} \rangle_{\iota} \rangle_{\iota}$ (обозначим её K''), для которой $parti(K'') = 1$. Наконец, рассмотрим $\langle_{\iota} \rangle_{\iota}$ (обозначим её K'''), для которой $parti(K''') = 1$. Следовательно, ширина КС-выражения ζ равна $width(\zeta) = 3$.

Заметим, что КС-выражения из $Core(\zeta, 1)$ сами по себе могут служить правилами вывода для порождения всего языка. Это возможно, поскольку случаи с глубиной $d > 1$ соответствуют повторению левосторонних и правосторонних циклов, уже заложенных в этих правилах.

D. L-граф

Понятие L-графа введено в [6]. L-граф представляет собой ориентированный граф, на дугах которого расположены пометки — символьные из алфавита основных символов и дополнительные скобочные, которые влияют на успешность прохождения пути из начальной вершины в заключительную (требуется баланс по скобкам).

Здесь мы можем представить язык, задаваемый L-графом, и предложить формат представления путей в L-графе.

Определение 12: Определим множество *успешных путей* L-графа G как

$$\begin{aligned} Sentences(G) = \{T \mid beg(T) \in I, end(T) \in \\ F, \mu(\iota_i(T)) = \varepsilon, i = 1, 2\}. \end{aligned} \quad (8)$$

Определение 13: Язык, задаваемый L-графом G , есть подмножество

$$L(G) = \bigcup_{T \in Sentences(G)} \omega(T) \quad (9)$$

множества Σ^* .

Формат последовательности, соответствующей отображению пути. Введем морфизм

$$\Phi : E^* \rightarrow (V \times (\Sigma \cup \{\varepsilon\}) \times (P \cup \{\varepsilon\}))^* \times V,$$

сопоставляющий путь T в L-графе G последовательность троек (начальная вершина, пометка дуги, скобочный

след) для всех дуг пути T в порядке их следования, дополненную в конце заключительной вершиной последней дуги пути T .

Пример 3: Рассмотрим L-граф $G =$

$\langle \{q_0, q_1, q_2\}, \{a, b, c\}, \{<_1, >_1\}, E, \{q_0\}, \{q_2\} \rangle$, где $E = \{(q_0, a, <_1, \varepsilon, q_0), (q_0, b, \varepsilon, \varepsilon, q_1), (q_1, a, >_1, \varepsilon, q_1), (q_1, c, \varepsilon, \varepsilon, q_2), (q_2, b, \varepsilon, \varepsilon, q_2)\}$, изображенный на рисунке 1.




Рис. 1. Пример L-графа G

Согласно построенному L-графу G , мы можем записать его $Core(G, 1, 1) \cap Sentences(G)$ как

$$\left\{ \begin{array}{l} \rightarrow q_0 \xrightarrow{b} q_1 \xrightarrow{c} q_2 \rightarrow, \\ \rightarrow q_0 \xrightarrow{a} q_0 \xrightarrow{b} q_1 \xrightarrow{a} q_1 \xrightarrow{c} q_2 \rightarrow, \\ \rightarrow q_0 \xrightarrow{b} q_1 \xrightarrow{c} q_2 \xrightarrow{b} q_2 \rightarrow, \\ \rightarrow q_0 \xrightarrow{a} q_0 \xrightarrow{b} q_1 \xrightarrow{a} q_1 \xrightarrow{c} q_2 \xrightarrow{b} q_2 \rightarrow \end{array} \right\}.$$

Здесь видим, что цикл $q_2 \xrightarrow{b} q_2$ является нейтральным циклом, поскольку он сбалансирован по скобкам.

III. ПРЕОБРАЗОВАНИЕ БЕСКОНТЕКСТНОГО ВЫРАЖЕНИЯ В ЭКВИВАЛЕНТНЫЙ L-ГРАФ

A. Базовые и обобщенные конструкции КС-выражений и L-графов

Согласно определению КС-выражений, выделим пять их форм. Если КС-выражение ζ относится к одной из этих форм, то соответствующий L-граф G может быть построен непосредственно либо методом подграфов. Базовые конструкции (БК) и обобщённые конструкции (ОК) рассматриваются ниже следующим образом:

- 1) элементарный символ: для КС-выражения $\zeta = a$, где $a \in \Sigma \cup \{\varepsilon\}$, соответствующий L-граф $G = \langle \{q_0, q_1\}, \{a\}, \{\varepsilon\}, \{(q_0, a, \varepsilon, \varepsilon, q_1)\}, \{q_0\}, \{q_1\} \rangle$ (рис. 2);




Рис. 2. БК-1: элементарный символ

для КС-выражения $\zeta = \alpha$, где $\alpha \in \Sigma^*$, соответствующий L-граф $G = \langle \{q_0, \dots, q_n\}, \Sigma_\alpha, \{\varepsilon\}, E, \{q_0\}, \{q_n\} \rangle$, где $E = E_\alpha \cup \{(q_0, \varepsilon, \varepsilon, \varepsilon, q_{\alpha_{start}}), (q_{\alpha_{end}}, \varepsilon, \varepsilon, \varepsilon, q_n)\}$ (рис. 3);




Рис. 3. ОК-1: элементарный символ

- 2) сумма: для КС-выражения $\zeta = a + b$, где $a, b \in \Sigma$, соответствующий L-граф $G = \langle \{q_0, q_1\}, \{a, b\}, \{\varepsilon\}, E, \{q_0\}, \{q_1\} \rangle$, где $E = \{(q_0, a, \varepsilon, \varepsilon, q_1), (q_0, b, \varepsilon, \varepsilon, q_1)\}$ (рис. 4);




Рис. 4. БК-2: сумма

для КС-выражения $\zeta = \alpha + \beta$, где α, β — КС-выражения, соответствующий L-граф $G = \langle \{q_0, \dots, q_n\}, \Sigma_\alpha \cup \Sigma_\beta, \mathcal{B}_\alpha \cup \mathcal{B}_\beta, E, \{q_0\}, \{q_n\} \rangle$, где $E = E_\alpha \cup E_\beta \cup \{(q_0, \varepsilon, \varepsilon, \varepsilon, q_{\alpha_{start}}), (q_0, \varepsilon, \varepsilon, \varepsilon, q_{\beta_{start}}), (q_{\alpha_{end}}, \varepsilon, \varepsilon, \varepsilon, q_n), (q_{\beta_{end}}, \varepsilon, \varepsilon, \varepsilon, q_n)\}$ (рис. 5);




Рис. 5. ОК-2: сумма

- 3) произведение: для КС-выражения $\zeta = ab$, где $a, b \in \Sigma$, соответствующий L-граф $G = \langle \{q_0, q_1, q_2\}, \{a, b\}, \{\varepsilon\}, E, \{q_0\}, \{q_2\} \rangle$, где $E = \{(q_0, a, \varepsilon, \varepsilon, q_1), (q_1, b, \varepsilon, \varepsilon, q_2)\}$ (рис. 6);




Рис. 6. БК-3: произведение

для КС-выражения $\zeta = \alpha\beta$, где α, β — КС-выражения, соответствующий L-граф $G = \langle \{q_0, \dots, q_n\}, \Sigma_\alpha \cup \Sigma_\beta, \mathcal{B}_\alpha \cup \mathcal{B}_\beta, E, \{q_0\}, \{q_n\} \rangle$, где $E = E_\alpha \cup E_\beta \cup \{(q_{\alpha_{end}}, \varepsilon, \varepsilon, \varepsilon, q_{\beta_{start}})\}$ (рис. 7);






Рис. 7. ОК-3: произведение

- 4) ι -гнездо: для КС-выражения $\zeta = <_\iota(a)b(c)>_\iota$, где $a, b, c \in \Sigma$, соответствующий L-граф $G = \langle \{q_0, q_1\}, \{a, b, c\}, \{<_\iota, >_\iota\}, E, \{q_0\}, \{q_1\} \rangle$, где $E = \{(q_0, a, <_\iota, \varepsilon, q_0), (q_0, b, \varepsilon, \varepsilon, q_1), (q_1, c, >_\iota, \varepsilon, q_1)\}$ (рис. 8);

Рис. 8. БК-4: l -гнездо

для КС-выражения $\zeta = \langle_l(\alpha)\beta(\gamma)\rangle_l$, где α, β, γ — КС-выражения, соответствующий L-граф $G = \langle\{q_0, \dots, q_n\}, \Sigma_\alpha \cup \Sigma_\beta \cup \Sigma_\gamma, \mathcal{B}_\alpha \cup \mathcal{B}_\beta \cup \mathcal{B}_\gamma \cup \{\langle_l, \rangle_l\}, E, \{q_0\}, \{q_n\}\rangle$, где $E = E_\alpha \cup E_\beta \cup E_\gamma \cup \{(q_0, \varepsilon, \langle_l, \varepsilon, q_{\alpha_{start}}), (q_{\alpha_{end}}, \varepsilon, \varepsilon, \varepsilon, q_0), (q_0, \varepsilon, \varepsilon, \varepsilon, q_{\beta_{start}}), (q_{\beta_{end}}, \varepsilon, \varepsilon, \varepsilon, q_n), (q_n, \varepsilon, \rangle_l, \varepsilon, q_{\gamma_{start}}), (q_{\gamma_{end}}, \varepsilon, \varepsilon, \varepsilon, q_n)\}$ (рис. 9);

Рис. 9. ОК-4: l -гнездо

- 5) нейтральный цикл: для КС-выражения $\zeta = [b]$, где $b \in \Sigma$, соответствующий L-граф $G = \langle\{q_0\}, \{b\}, \{\varepsilon\}, \{(q_0, b, \varepsilon, \varepsilon, q_0)\}, \{q_0\}, \{q_0\}\rangle$ (рис. 10);




Рис. 10. БК-5: нейтральный цикл

для КС-выражения $\zeta = [\beta]$, где β — КС-выражение, соответствующий L-граф $G = \langle\{q_0, \dots\}, \Sigma_\beta, \{\varepsilon\}, E_\beta \cup \{(q_0, \varepsilon, \varepsilon, \varepsilon, q_{\beta_{start}}), (q_{\beta_{end}}, \varepsilon, \varepsilon, \varepsilon, q_0)\}, \{q_0\}, \{q_0\}\rangle$ (рис. 11).




Рис. 11. ОК-5: нейтральный цикл

В. Устранение избыточных вершин из L-графа

При взаимном соединении построенных обобщенных конструкций могут возникать некоторые избыточные конструкции. Мы можем исключить избыточные вершины и получить эквивалентный L-граф, описывающий тот же язык.

Анализируя конструкции, в частности конструкции суммы и произведения, можно заметить, что они соответствуют параллельному и последовательному соединению элементарных символов соответственно.

Если КС-выражение начинается и/или заканчивается элементарным символом (т. е. $\alpha = a\alpha'b$, $a, b \in \Sigma$), соответствующие начальную и/или конечную вершины L-графа можно объединить, исключив избыточные ε -дуги. При этом отдельные вершины для параллельного

соединения не требуются (рис. 12). Аналогичное устранение применимо и к последовательному соединению (рис. 13).




Рис. 12. Упрощение конструкции суммы





Рис. 13. Упрощение конструкции произведения

Конструкции l -гнездо и нейтральный цикл требуют, чтобы их скобки были сбалансированы. l -гнездо представляет собой два парных цикла (левый и правый) с заключенной между ними центральной частью. При этом как парная структура циклов, так и центральная часть должны быть сбалансированы по скобкам. В отличие от этого, нейтральный цикл является просто циклом, имеющим сбалансированные скобки.

По аналогии с устранением вершин при последовательном соединении элементарных символов, можно выполнить аналогичное устранение вершин для последовательно соединенных l -гнезд (рис. 14).

Рис. 14. Упрощение конструкции произведения l -гнезда

Более детальные аспекты оптимизации L-графов, в частности сопряжение L-графов, будут исследованы в наших последующих работах.

С. Алгоритм преобразования КС-выражения в эквивалентный L-граф

Алгоритм 1: Для заданного КС-выражения ζ необходимо построить алгоритм $\mathcal{A}_{E \rightarrow L}(\zeta)$ для преобразования КС-выражения ζ в соответствующий L-граф G :

$$G := \mathcal{A}_{E \rightarrow L}(\zeta).$$

Вход: КС-выражение $\zeta \neq \emptyset$.

Выход: соответствующий эквивалентный L-граф G .

Шаг 1. Разложение на обобщенные конструкции.

Заданное КС-выражение ζ разделим по сомножителям:

$$\zeta = \xi_1 \cdot \dots \cdot \xi_i \cdot \dots \cdot \xi_n, \quad \xi_i \text{ — сомножитель } \zeta, \quad 1 \leq i \leq n.$$

Относим каждый сомножитель ξ_i к одному из пяти типов обобщённых конструкций.

Шаг 2. Построение подграфов для ОК-типов.

Строим рекурсивно для каждого ξ_i подграф согласно его типу:

- 1) ОК-1 (элементарный символ): вводим 2 новые вершины и добавляем 2 ε -дуги для соединения вершин;
- 2) ОК-2 (сумма): вводим 2 новые вершины и добавляем 4 ε -дуги для параллельного соединения подграфов;
- 3) ОК-3 (произведение): добавляем 1 ε -дугу для последовательного соединения подграфов;
- 4) ОК-4 (ι -гнездо): вводим 2 новые вершины и добавляем 2 скобочные дуги (парные скобки), 2 ε -дуги для связи с центральной частью и 2 ε -дуги для возврата к вершинам;
- 5) ОК-5 (нейтральный цикл): добавляем 2 ε -дуги для заикливания;

Шаг 3. Достижение базовой конструкции.

Завершаем рекурсию при достижении базовой конструкции, которую преобразуем в базовый L-граф напрямую.

Шаг 4. Объединяем все подграфы базовых конструкций.

Отмечаем, что при выполнении последовательного и параллельного соединений допускается устранение избыточных вершин, как описано в разделе III-B.

D. Эквивалентность КС-выражений и L-графов

Эквивалентность L-графа и КС-выражения заключается в том, что данное КС-выражение ζ и соответствующий L-граф G , полученный с помощью алгоритма преобразования в разделе III-C, задают один и тот же язык:

$$L(\mathcal{A}_{E \rightarrow L}(\zeta)) = L(\zeta). \quad (10)$$

Теорема 1: Язык задается КС-выражением тогда и только тогда, когда он определяется некоторым L-графом.

Следующие определения и лемма помогают нам доказать эквивалентность КС-выражений и L-графов.

Множество $V(\zeta)$ и $E(\zeta)$ представляют собой, соответственно множество вершин и множество дуг, полученные при преобразовании КС-выражения ζ в соответствующий L-граф G согласно алгоритму, описанному в разделе III-C.

Для $s \geq 0$ и $P, Q \in V(\zeta)$ введем обозначение $Path(P, Q, s)$ для множества всех путей в L-графе G между вершинами P и Q длины s , где длина пути определяется количеством дуг в нём. Пусть $Path(P, Q) = \cup_{s \geq 0} Path(P, Q, s)$.

Определение 14: Назовем *путем* КС-выражения ζ элемент следующего рекурсивно определяемого множества $PathE(\zeta)$:

$$PathE(\zeta) = Clan(\zeta) \cup \{x(<_{\iota}(u))^k y(>_{\iota}(v))^l z \mid x <_{\iota}(u) y(v) >_{\iota} z \in PathsE(\zeta), k, l \geq 0\}. \quad (11)$$

Для $s \geq 0$ и $a_1, a_2 \in \mathcal{A}(\zeta)$ введем обозначение $StrE(a_1, a_2, s)$ для множества всех цепочек

длины s , порождённых участками путей КС-выражения ζ , начинающихся с a_1 и заканчивающихся a_2 . Пусть $StrE(a_1, a_2) = \cup_{s \geq 0} StrE(a_1, a_2, s)$.

Введем морфизм

$$\psi : E^* \rightarrow (\Sigma^* \times P)^*,$$

который преобразует путь, удаляя все вершины и ε -дуги, объединяя пометки дуг с соответствующими скобочными следами (при этом для нейтральных циклов полученная комбинация заключается в квадратные скобки).

Лемма 1: Для любых $P, Q \in V(\zeta)$, если $Path(P, Q, s) \neq \emptyset$, то существует такая биекция

$$\varphi : Path(P, Q) \rightarrow StrE(a_1, a_2),$$

что для каждого $T \in Path(P, Q)$ выполняется равенство

$$\psi(T) = \varphi(T). \quad (12)$$

Доказательство. Рассмотрим случай $s = 0$. Тогда $Path(P, Q) = \{\Lambda\}$, $StrE(a_1, a_2) = \{\Lambda\}$. Следовательно, в данном случае лемма верна.

Пусть $s > 0$. Из базовых конструкций и обобщённых конструкций, используя представление формата последовательности пути для $Path(P, Q)$, получаем:

$$1) \text{ БК-1: } Path(q_0, q_1) = \{\rightarrow q_0 \xrightarrow{a} q_1 \rightarrow\};$$

$$\text{ОК-1: } a \in \Sigma_{\alpha}, Path(P, Q) =$$

$$\left\{ \begin{array}{c} \rightarrow q_0 \xrightarrow{\varepsilon} q_n \rightarrow, \\ \dots \\ P \dots \xrightarrow{a} \dots Q, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\alpha_{start}} \dots q_{\alpha_{end}} \xrightarrow{\varepsilon} q_n \rightarrow \end{array} \right\};$$

$$2) \text{ БК-2: } Path(q_0, q_1) =$$

$$\{\rightarrow q_0 \xrightarrow{a} q_1 \rightarrow, \rightarrow q_0 \xrightarrow{b} q_1 \rightarrow\};$$

$$\text{ОК-2: } a \in \Sigma_{\alpha}, b \in \Sigma_{\beta}, Path(P, Q) =$$

$$\left\{ \begin{array}{c} \rightarrow q_0 \xrightarrow{\varepsilon} q_n \rightarrow, \\ \dots \\ P \dots \xrightarrow{a} \dots Q, \\ P \dots \xrightarrow{b} \dots Q, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\alpha_{start}} \dots q_{\alpha_{end}} \xrightarrow{\varepsilon} q_n \rightarrow, \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\beta_{start}} \dots q_{\beta_{end}} \xrightarrow{\varepsilon} q_n \rightarrow \end{array} \right\};$$

$$3) \text{ БК-3: } Path(q_0, q_2) =$$

$$\{\rightarrow q_0 \xrightarrow{a} q_1, q_1 \xrightarrow{b} q_2 \rightarrow, \rightarrow q_0 \xrightarrow{a} q_1 \xrightarrow{b} q_2 \rightarrow\};$$

$$\text{ОК-3: } a \in \Sigma_{\alpha}, b \in \Sigma_{\beta}, Path(P, Q) =$$

$$\left\{ \begin{array}{l} \rightarrow q_0 \xrightarrow{\varepsilon} q_n \rightarrow, \\ \dots \\ P \dots \xrightarrow{a} \dots \xrightarrow{b} \dots Q, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\alpha_{start}} \dots q_{\alpha_{end}} \xrightarrow{\varepsilon} \\ q_{\beta_{start}} \dots q_{\beta_{end}} \xrightarrow{\varepsilon} q_n \rightarrow \end{array} \right\};$$

4) БК-4: $Path(q_0, q_2) = \{ \rightarrow q_0 \xrightarrow{a} q_0, \rightarrow q_0 \xrightarrow{b} q_1 \rightarrow, q_1 \xrightarrow{c} q_1 \rightarrow, \rightarrow q_0 \xrightarrow{a} q_0 \xrightarrow{b} q_1, q_0 \xrightarrow{b} q_1 \xrightarrow{c} q_1 \rightarrow, \rightarrow q_0 \xrightarrow{a} q_0 \xrightarrow{b} q_1 \xrightarrow{c} q_1 \rightarrow, \dots \};$

ОК-4: $a \in \Sigma_\alpha, b \in \Sigma_\beta, c \in \Sigma_\gamma, Path(P, Q) =$

$$\left\{ \begin{array}{l} \rightarrow q_0 \xrightarrow{\varepsilon} q_n \rightarrow, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} \dots \xrightarrow{a} \dots \xrightarrow{\varepsilon} q_0, \\ \dots \\ P \dots \xrightarrow{b} \dots Q, \\ \dots \\ q_n \xrightarrow{\varepsilon} \dots \xrightarrow{c} \dots \xrightarrow{\varepsilon} q_n \rightarrow, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\alpha_{start}} \dots q_{\alpha_{end}} \xrightarrow{\varepsilon} q_0 \\ \xrightarrow{\varepsilon} q_{\beta_{start}} \dots q_{\beta_{end}} \xrightarrow{\varepsilon} \\ q_n \xrightarrow{\varepsilon} q_{\gamma_{start}} \dots q_{\gamma_{end}} \xrightarrow{\varepsilon} q_n \rightarrow \end{array} \right\};$$

5) БК-5: $Path(q_0, q_0) = \{ \rightarrow q_0 \xrightarrow{b} q_0 \rightarrow, \rightarrow q_0 \xrightarrow{b} q_0 \rightarrow q_0 \rightarrow, \dots \};$

ОК-5: $b \in \Sigma_\beta, Path(P, Q) =$

$$\left\{ \begin{array}{l} \rightarrow q_0 \xrightarrow{\varepsilon} q_0 \rightarrow, \\ \dots \\ P \dots \xrightarrow{b} \dots Q, \\ \dots \\ \rightarrow q_0 \xrightarrow{\varepsilon} q_{\beta_{start}} \dots q_{\beta_{end}} \xrightarrow{\varepsilon} q_0 \rightarrow \end{array} \right\};$$

Применяя морфизм ψ к пяти типам путей, получаем:

- 1) БК-1: $\{a\}$; ОК-1: $\{\dots a \dots\}$;
- 2) БК-2: $\{a, b\}$; ОК-2: $\{\dots a \dots, \dots b \dots\}$;
- 3) БК-3: $\{a, b, ab\}$;
ОК-3: $\{\dots a \dots, \dots b \dots, \dots a \dots b \dots\}$;
- 4) БК-4: $\{<_l(a), b, (c)>_l, <_l(a)b, b(c)>_l, <_l(a)b(c)>_l, \dots\}$;
ОК-4: $\{<_l(\dots a \dots), \dots b \dots, (\dots c \dots)>_l, <_l(\dots a \dots) \dots b \dots (\dots c \dots)>_l, \dots\}$;
- 5) БК-5: $\{[b], [b][b], \dots\}$;
ОК-5: $\{[\dots b \dots], [\dots b \dots][\dots b \dots], \dots\}$.

Анализ показывает, что построенные множества пяти типов путей находятся в точном соответствии с $StrE(a_1, a_2)$. Следовательно, определенное отображение φ образует требуемую биекцию. $\square$

Следствие 1: $L(\mathcal{A}_{E \rightarrow L}(\zeta)) = L(\zeta)$.

Доказательство. По лемме существует такая биекция

$$\varphi : Sentences(\mathcal{A}_{E \rightarrow L}(\zeta)) \rightarrow Clan(\zeta),$$

что для каждого успешного пути $T \in Sentences(\mathcal{A}_{E \rightarrow L}(\zeta))$ выполняется равенство

$$\psi(T) = \varphi(T).$$

Следовательно,

$$\omega(T) = projection(\varphi(T), \Sigma).$$

Значит,

$$L(\mathcal{A}_{E \rightarrow L}(\zeta)) = L(\zeta). \square$$

Пример 4: Мы построим соответствующий L-граф, используя $Core(\zeta, 1)$ из КС-выражения, приведённого в примере 2.

Рассмотрим КС-выражение $\zeta =$

$$x[a]y[<_1(a)b(a)>_1u][b]<_2(c)d(a+c)>_2z].$$

Шаг 1. Заданное КС-выражение разделим по сомножителям:

$$\underbrace{x}_{\text{БК-1}} \cdot \underbrace{[a]}_{\text{БК-5}} \cdot \underbrace{y}_{\text{БК-1}} \cdot \underbrace{[<_1(a)b(a)>_1u][b]<_2(c)d(a+c)>_2z]}_{\text{ОК-5}}$$

Шаг 2. Построение подграфов для ОК-типов (рис. 15).




Рис. 15. Построение подграфа для ОК-5

Шаг 3. Повторяем шаги 1 и 2 до тех пор, пока не перестанут появляться ОК-типы.

Шаг 3.1 Заданное КС-выражение разделим по сомножителям:

$$\underbrace{[<_1(a)b(a)>_1u]}_{\text{ОК-5}} \cdot \underbrace{[b]}_{\text{БК-5}} \cdot \underbrace{<_2(c)d(a+c)>_2}_{\text{ОК-4}} \cdot \underbrace{z}_{\text{БК-1}}$$

Шаг 3.2. Построение подграфов для ОК-типов (рис. 16 и рис. 17).




Рис. 16. Построение подграфа для ОК-5




Рис. 17. Построение подграфа для ОК-4

Шаг 3.3. Повторяем шаги 1 и 2 до тех пор, пока не перестанут появляться ОК-типы.

Шаг 3.3.1 Заданное КС-выражение разделим по сомножителям:

$$\underbrace{\langle_1(a)b(a)\rangle_1}_{\text{БК-4}} \cdot \underbrace{u}_{\text{БК-1}} \quad \underbrace{a+c}_{\text{БК-2}}$$

Шаг 3.3.2. Построение подграфов для ОК-типов.

Шаг 4. Объединяем все подграфы базовых конструкций (рис. 18).




Рис. 18. Полученный эквивалентный L-граф

IV. ЗАКЛЮЧЕНИЕ

Уточнена классификация видов скобок в бесконтекстных выражениях. Разработан алгоритм преобразования бесконтекстных выражений в эквивалентные L-графы, и доказана корректность их эквивалентности. Предложена идея устранения избыточных вершин из L-графа.

БЛАГОДАРНОСТИ

Результаты настоящего исследования были получены при финансовой поддержке Правительства г. Шэньчжэня и Университета МГУ-ППИ в Шэньчжэне.

Список литературы

- [1] Хопкрофт Д. Э., Мотвани Р., Ульман Д. Д. Введение в теорию автоматов, языков и вычислений / Под ред. А. Б. Ставровский. — 2 изд. — М. : Издательский дом «Вильямс», 2008. — 528 с. — Пер. с англ.: Hopcroft J. E., Motwani R., Ullman J. D. Introduction to Automata Theory, Languages, and Computation. 2nd ed.
- [2] Волкова И. А., Вылиток А. А., Руденко Т. В. Формальные грамматики и языки. Элементы теории трансляции. — 3 изд. — М. : Издательский отдел факультета ВМиК МГУ им. М. В. Ломоносова, 2009. — 115 с.
- [3] Ахо А., Ульман Дж. Теория синтаксического анализа, перевода и компиляции / Под ред. В. М. Курочкин. — М. : Мир, 1978. — Т. 1. — Пер. с англ.: Aho A., Ullman J. The Theory of Parsing, Translation and Compiling. Vol. 1.
- [4] Станевичене Л. И. К теории бесконтекстных языков. — М., 2000. — Деп. в ВИНТИ РАН 29.05.2000, №1546-B00.
- [5] Гомозов А. Л., Станевичене Л. И. Об одном обобщении регулярных выражений // Программирование. — 2000. — № 5. — С. 31–43. — Библиогр.: с.43.
- [6] Вылиток А. А., Сутырин П. Г. Характеризация формальных языков графами // Сборник тезисов научной конференции «Тихоновские чтения». — Москва, МГУ имени М. В. Ломоносова, факультет ВМК, 2010. — С. 82–83.
- [7] Станевичене Л. И. О некоторых определениях класса КС-языков видеоданных // Программирование. — 1999. — № 5. — С. 15–25. — УДК 519.682.1.

МУ Цзинъюань,
аспирант Университета МГУ–ППИ в Шэньчжэне
(<http://szmsubit.ru/>),
email: xirousang@gmail.com.

Algorithm for transforming context-free expressions into equivalent L-graphs

Mu Jingyuan

Abstract—This work examines context-free grammars and their alternative representations—context-free expressions and context-free L-graphs. A context-free expression serves as an algebraic form for representing context-free grammars, matching known methods in conciseness while simultaneously providing a more detailed and visual demonstration of how language strings are generated from subordinate strings. A context-free L-graph is a directed graph whose arcs are labeled with symbols from a primary alphabet and additional bracket markers that affect the successful traversal of a path from the initial vertex to the final vertex (bracket balance is required).

This article focuses on the algorithm for converting context-free expressions into equivalent L-graphs. The proposed algorithm is accompanied by a correctness proof and incorporates the idea of removing redundant vertices. Such a synthesis of algebraic and graphical approaches combines their key advantages: on one hand, context-free expressions ensure compact and clear descriptions, while on the other hand, context-free L-graphs provide intuitive visualization of the language structure. This combined approach opens prospects for developing more effective tools for analyzing and transforming language models in compilers and text processing systems.

Keywords—context-free expression, extension of regular expressions, context-free grammar, context-free L-graph.

References

- [1] Hopcroft J.E., Motwani R., Ullman J.D. Introduction to Automata Theory, Languages, and Computation / Ed. by A. B. Stavrovsky. — 2nd ed. — Moscow : Williams Publishing House, 2008. — 528 p. — Translation from English: Hopcroft J. E., Motwani R., Ullman J. D. Introduction to Automata Theory, Languages, and Computation. 2nd ed.
- [2] Volkova I.A., Vylitok A.A., Rudenko T. V. Formal Grammars and Languages. Elements of Translation Theory. — 3rd ed. — Moscow : Lomonosov Moscow State University, Faculty of Computational Mathematics and Cybernetics Publishing Department, 2009. — 115 p.
- [3] Aho A., Ullman J. The Theory of Parsing, Translation and Compiling / Ed. by V. M. Kurochkin. — Moscow : Mir Publishers, 1978. — Vol. 1. — Translated from English: Aho A., Ullman J. The Theory of Parsing, Translation and Compiling. Vol. 1.
- [4] Stanevichene L.I. On the Theory of Context-Free Languages. — Moscow, 2000. — Deposited in VINITI RAS 29.05.2000, No. 1546-B00.
- [5] Gomofov A. L., Stanevichene L. I. On One Generalization of Regular Expressions // Programming and Computer Software. — 2000. — No. 5. — P. 31–43. — Bibliogr.: p.43.
- [6] Vylitok A. A., Sutyurin P. G. Characterization of Formal Languages by Graphs // Abstracts of the Scientific Conference "Tikhonov Readings". — Moscow, Lomonosov Moscow State University, Faculty of Computational Mathematics and Cybernetics, 2010. — P. 82–83.
- [7] Stanevichene L. I. On Some Definitions of the Class of Context-Free Languages // Programming and Computer Software. — 1999. — No. 5. — P. 15–25. — UDC 519.682.1.

MU Jingyuan,
Post-graduate student of Shenzhen MSU–BIT University,
China (<http://szmsubit.ru/>),
email: xirousang@gmail.com.