

Лекция 10

Теория формальных языков (II)

(Конспект: К. Ефремова)

10.1 Конечные автоматы (продолжение)

Определение 10.1. *Детерминированный конечный автомат* — это недетерминированный конечный автомат, у которого $\delta(q, \epsilon) = \emptyset$ и $|\delta(q, a)| \leq 1$. *Полностью определенным* детерминированным конечным автоматом называется автомат, у которого $|\delta(q, a)| = 1$. (Иначе говоря, можно считать, что у него $\delta : Q \times \Sigma \rightarrow Q$.)

Определение 10.2. Обозначение: $q_1 \xrightarrow{a} q_2$ означает $q_2 \in \delta(q_1, a)$.

Теорема 10.1. *Для любого недетерминированного конечного автомата $\mathcal{A} = (Q, \Sigma, q_s, F, \delta)$ можно построить полностью определенный детерминированный конечный автомат $\mathcal{A}' = (Q', \Sigma, q'_s, F', \delta')$, такой, что $L(\mathcal{A}) = L(\mathcal{A}')$.*

Доказательство. 1. Избавимся от ϵ -переходов. Найдем все пары состояний (q_1, q_2) , такие, что q_2 достижимо из q_1 по ϵ -переходам: $q_1 \xrightarrow{\epsilon} q' \xrightarrow{\epsilon} \dots \xrightarrow{\epsilon} q_2$. Для каждого не- ϵ -перехода $q_2 \xrightarrow{a} q_3$ добавим переход $q_1 \xrightarrow{a} q_3$. Кроме того, если $q_2 \in F$, добавим и q_1 в F .

После этого удалим все ϵ -переходы. Заметим, что язык при этом не изменится. Действительно, раньше мы шли по пути $q_1 \rightarrow \dots \rightarrow q_2 \rightarrow q_3$, считывая a , а теперь по другому пути, но все равно считываем a ; и наоборот.

2. Пусть $Q' = 2^Q$; $q'_s = \{q_s\}$; $F' = \{q' \in Q' \mid q' \cap F \neq \emptyset\}$. Напишем новые переходы вида $q'_1 \xrightarrow{a} q'_2$, где $q'_2 = \{q \in Q \mid \exists r \in q'_1 : r \xrightarrow{a} q\}$. Построенный новый автомат, очевидно, детерминированный.

Докажем, что язык не меняется.

(а) Пусть старый автомат принимает строчку. Покажем, что новый автомат тоже примет эту строчку. Раньше мы совершали переход $q_s \xrightarrow{a_1} q_1$, теперь — переход $\{q_s\} \xrightarrow{a_1} \{q_1, \dots\}$. Последующие переходы $q_{i-1} \xrightarrow{a_i} q_i$ превращаются в $\{q_{i-1}, \dots\} \xrightarrow{a_i} \{q_i, \dots\}$. Последнее состояние будет принадлежать F' , ибо оно содержит конечное состояние старого автомата.

(б) Пусть строчка принимается новым автоматом. По определению, в состоянии, в котором он завершает работу, содержится некоторое конечное состояние старого автомата. Пусть последний переход нового автомата — $q' \xrightarrow{a} \{p, \dots\}$ (где $p \in F$). По определению новой функции перехода, существует $q \in q'$, такое, что $q \xrightarrow{a} p$ в старом автомате. Далее рассмотрим предыдущий переход $r' \xrightarrow{b} \{q, \dots\}$ в новом автомате, и т. д., пока не дойдем до стартового состояния. \square

Теорема 10.2. *Множества языков, задаваемых*

- (1) *конечными автоматами,*
- (2) *регулярными выражениями,*
- (3) *праволинейными грамматиками*

в одном и том же алфавите Σ , совпадают.

Доказательство. (2) \Rightarrow (1). Доказательство по индукции.

База:

1. Пустой язык. Автомат, принимающий пустой язык — автомат с пустым F .
2. Язык $\{\epsilon\}$. В автомате, принимающем его, $F = \{q_s\}$, а переходов в нем нет.
3. Язык $\{a\}$. Единственный переход такого автомата: $q_s \xrightarrow{a} q$; $F = \{q\}$.

Индукционный переход:

1. Рассмотрим конкатенацию языков L_1 и L_2 . Пусть есть автомат, принимающий язык L_1 ; и другой автомат, принимающий L_2 . Мы хотим построить автомат, принимающий $L_1 \cdot L_2$.

Объединим эти два автомата в один, и слегка модифицируем его. Новым стартовым состоянием будет стартовое состояние первого автомата. Новым множеством конечных состояний будет множество конечных состояний второго автомата. Также добавим ϵ -переходы из (бывших) конечных состояний первого автомата в (бывшее) начальное состояние второго автомата.

2. $L_1 \cup L_2$. Снова объединим два автомата. Добавим новое стартовое состояние, а из него — ϵ -переходы в два старых стартовых состояния. На сей раз конечными состояниями построенного автомата будут конечные состояния обоих автоматов.
3. L^* . Добавим ϵ -переходы из конечных состояний — в начальное, а также добавим ϵ -переход из стартового состояния в *новое* (дополнительное) конечное состояние.

(1) \Rightarrow (3). Нетерминалы грамматики — состояния автомата. Если $q \xrightarrow{a} p$, то добавим правило $q \rightarrow ap$. Если еще и $p \in F$, то добавим еще правило $q \rightarrow a$.

(3) \Rightarrow (2). Можно построить систему уравнений

$$\begin{aligned} A_1 &= \alpha_{10} \cup (\alpha_{11}A_1) \cup (\alpha_{12}A_2) \dots \cup (\alpha_{1n}A_n) \\ A_2 &= \alpha_{20} \cup (\alpha_{21}A_1) \cup (\alpha_{22}A_2) \dots \cup (\alpha_{2n}A_n) \\ &\dots \\ A_n &= \alpha_{n0} \cup (\alpha_{n1}A_1) \cup (\alpha_{n2}A_2) \dots \cup (\alpha_{nn}A_n), \end{aligned}$$

где A_1, A_2, \dots, A_n — все нетерминалы, они же неизвестные этой системы уравнений; α_{ij} — регулярные выражения в алфавите Σ , коэффициенты системы, строятся они следующим образом. Посмотрим все правила для нетерминала A_i , у которых в правой части A_j ; пусть это $A_i \rightarrow a_1A_j, \dots, A_i \rightarrow a_kA_j$. Тогда $\alpha_{ij} := \{a_1\} \cup \{a_2\} \cup \dots \cup \{a_k\}$. (Если $j = 0$, рассматриваем правила, не содержащие нетерминала в правой части.)

Исключим A_1 : перепишем первое неравенство в виде $A_1 = (\alpha_{11}A_1) \cup \beta$; теперь $A_1 = \alpha_{11}^* \beta$ (где $\beta \in (\Sigma \cup N)^*$) подставляем везде в последующие уравнения системы. Аналогично поступаем с A_2, \dots, A_n , находя A_i из i -го уравнения. Найдя, таким образом, регулярное выражение (уже в алфавите Σ , а не $\Sigma \cup N$) для A_n , подставим его в предыдущие уравнения, и т. д. В результате будет получено решение, которое будет минимальным¹, т. е. не будет содержать других решений; значения для нетерминалов будут, очевидно, будут регулярными выражениями. Значение для стартового нетерминала — искомое² регулярное выражение. \square

Задача 10.1. Завершить доказательство теоремы 10.2: доказать, что найденное так «решение» действительно будет минимальным решением, а также, что минимальное решение (точнее, соответствующее выражение для стартового нетерминала) действительно является языком, порождаемым данной грамматикой. \square

¹См. задачу 10.1.

²См. задачу 10.1.

Лемма 10.1 (лемма о разрастании для регулярных языков (pumping lemma)). Пусть L — регулярный язык. Тогда существует константа c , такая, что любую строку $x \in L$ длины не менее c можно разбить на три части $x = u \cdot v \cdot w$, такие что $0 < |v| \leq c$ и $\forall i \geq 0$ $u \cdot v^i \cdot w \in L$.

Доказательство. Рассмотрим детерминированный конечный полностью определенный автомат для языка L . Пусть $c = |Q| + 1$. Посмотрим, как он работает на цепочке $x: q_s \rightarrow q_1 \rightarrow \dots \rightarrow q_k \in F$. На каждом шаге считывается некоторый символ. Поскольку $|x| \geq c$, мы должны были побывать в каком-то состоянии дважды, и в нашем пути есть циклы. Выберем несамопересекающийся цикл; пусть до первого прохождения по нему считывалась строка u , при прохождении по нему считывалась строка v (ее длина не превосходит c , поскольку цикл — несамопересекающийся), а после прохождения по нему (в том числе, если по нему пошли еще раз) — строка w . Очевидно, наш автомат примет любую строку вида $uv^i w$. \square

С помощью этой леммы можно доказывать, что какой-нибудь язык не является регулярным.

Пример 10.1. $L = \{0^n 1^n \mid n \in \mathbb{N} \cup 0\}$ не является регулярным.

Доказательство. Пусть регулярный. Рассмотрим варианты подстроки v из леммы.

1. В строку попадают только нули \Rightarrow в uv^2w количество 0 увеличится, а количество 1 останется неизменным \Rightarrow строка не будет принадлежать L .
2. В строку попадают только единицы — аналогично.
3. $v = 0^i 1^j \Rightarrow$ в uv^2w после 1 будет идти 0 \Rightarrow строка опять не будет принадлежать языку.

(Замечание: тем не менее, этот язык может быть порожден *бесконтекстной* грамматикой $S \rightarrow 0S1, S \rightarrow \epsilon$.) \square

Полезные свойства регулярных языков:

1. Множество всех регулярных языков в данном алфавите замкнуто относительно операций, которые их порождают: $\cup, \cdot, *$.
- 2.

Лемма 10.2. Множество всех регулярных языков в данном алфавите замкнуто относительно дополнения.

Доказательство. Рассмотрим детерминированный конечный полностью определенный автомат, задающий язык L . Поменяем местами его конечные состояния с остальными: $F' := Q \setminus F$. Полученный автомат задает язык \bar{L} . \square

3.

Следствие 10.1. *... и замкнуто относительно пересечения.*

Разрешимые проблемы, связанные с регулярными языками:

1. Принадлежность. Рассмотрим детерминированный конечный полностью определенный автомат, принимающий данный язык. Чтобы узнать, принадлежит ли этому языку некоторая строка, запустим наш автомат на этой строке x . После $|x|$ переходов мы поймем, принадлежит ли она языку.
2. Пустота языка. Чтобы решить эту проблему, достаточно проверить, достижимо ли какое-нибудь конечное состояние автомата из начального. Эта задача, очевидно, алгоритмически разрешима.
3. Равенство языков. Чтобы построить алгоритм для этой задачи, достаточно заметить, что

$$L_1 = L_2 \Leftrightarrow L_1 \cap \bar{L}_2 = \emptyset \wedge L_2 \cap \bar{L}_1 = \emptyset \text{ (или: } (L_1 \cap \bar{L}_2) \cup (L_2 \cap \bar{L}_1) = \emptyset \text{)}.$$

4. Включение языков. Чтобы построить алгоритм для этой задачи, достаточно заметить, что

$$L_1 \subseteq L_2 \Leftrightarrow (L_1 \cap \bar{L}_2 = \emptyset) \text{ (или: } (L_1 \cap L_2 = L_1 \text{))}.$$