

## Задание 2

### НКА и алгоритмы поиска подстрок

#### **Литература:**

1. *Хопкрофт Д., Мотвани Р., Ульман Д.*  
Введение в теорию автоматов, языков и вычислений.  
М.: Вильямс, 2002.
2. *Aho A., Ульман Д.*  
Теория синтаксического анализа, перевода и компиляции  
М.: Мир, 1978. Гл. 0, 2.
3. *Серебряков В.А., Галочкин М.П., Гончар Д.Р., Фуругян М.Г.*  
Теория и реализация языков программирования.  
М.: МЗ-пресс, 2006.
4. *Шенъ. А. Х.*  
Программирование: теоремы и задачи  
М.: МЦНМО, 2004.
5. *Журавлёв Ю.И., Флёров Ю.А, Вялый М.Н.*  
Дискретный Анализ. Формальные системы и алгоритмы.  
М.: МЗ-пресс, 2010.

**Ключевые слова**<sup>1</sup>: язык, регулярные выражения, конкатенация, обединение, итерация, конечные автоматы (КА), детерминированные и недетерминированные КА, регулярные языки.

Упражнения из этого задания не обязательно тешать и присылать: они не оцениваются. Их стоит тешать, если вы хотите получить обратную связь. Задачи, помеченные звёздочкой, являются необязательными, но их решение сильно поощряется бонусными очками.

## 1 Построение по регулярному выражению конечного автомата

На семинаре мы разобрали алгоритм построения детерминированного конечного автомата по регулярному выражению. Однако, его нельзя на-

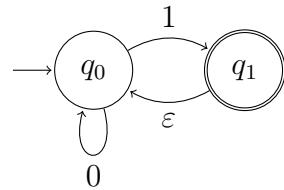
---

<sup>1</sup> минимальный необходимый объём понятий и навыков по этому разделу)

звать простым. Построить недетерминированный автомат по регулярному выражению гораздо проще. В каком-то смысле, если вы имеете дело с регулярным выражением, вы имеете дело с НКА.

Напомним, что помимо обычных переходов недетерминированные автоматы, имеют также  $\varepsilon$ -переходы, т.е. переходы вида  $\delta(q_i, \varepsilon) = q_j$ . Наличие таких переходов означает, что попав в состояние  $q_i$ , автомат может перейти в состояние  $q_j$  не обрабатывая следующий символ слова.

### Пример 1.



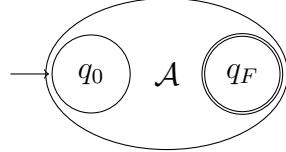
Легко видеть, что данный автомат принимает язык, состоящий из слов, оканчивающихся на 1. При прочтении 1, автомат переходит из состояния  $q_0$  в  $q_1$ , дальше, если во входном слове ещё остались необработанные символы, автомат делает  $\varepsilon$ -переход из состояния  $q_1$  в  $q_0$  и продолжает обработку слова.

Для построения НКА по РВ будем использовать определение регулярного языка. Напомним определение класса регулярных языков REG.

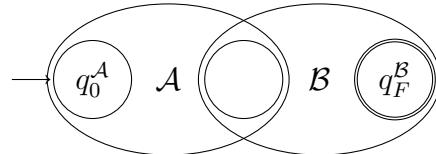
- $\emptyset \in \text{REG}.$
- $\forall \sigma \in \Sigma : \{\sigma\} \in \text{REG}.$
- $\forall X, Y \in \text{REG} : X \cdot Y, X|Y, X^* \in \text{REG}.$
- Больше нет регулярных языков.

Мы будем строить НКА по РВ из каждого пункта данного определения. С первыми двумя пунктами проблем нет – их я оставляю как лёгкое упражнение. Перейдём сразу к третьему пункту. Допустим уже построены автоматы  $\mathcal{A}$  и  $\mathcal{B}$  для регулярных языков  $X$  и  $Y$  соответственно. Мы будем предполагать, что оба автомата имеют всего одно принимающее состояние. Если в автомате несколько принимающих состояний, то можно построить эквивалентный ему автомат с единственным принимающим

состоянием, добавив к множеству состояний состояние  $q_F$ , которое будет единственным принимающим, и добавив  $\varepsilon$ -переходы в  $q_F$  из старого множества  $F$ :  $\forall q \in F : \delta(q, \varepsilon) = q_F$ . Будем схематично обозначать автоматы эллипсами, и помечать в них только начальное и принимающее состояния. Таким образом, автомат  $\mathcal{A}$  имеет вид



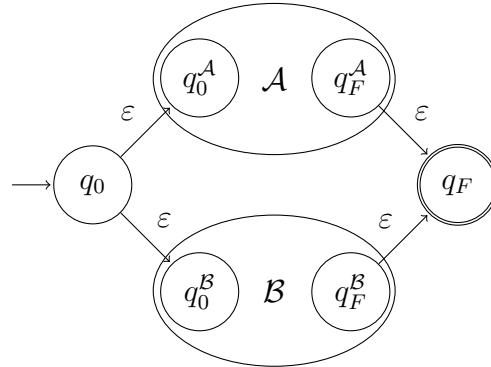
В дальнейшем, мы будем предполагать, что начальное состояние на схеме находится слева, а принимающее справа. Построим явно автомат распознающий  $X \cdot Y$ ,  $L(\mathcal{A}) = X, L(\mathcal{B}) = Y$ .



Для этого по автомата  $\mathcal{A}$  распознающему язык  $X$  и автомата  $\mathcal{B}$ , распознающему язык  $Y$  мы строим автомат, распознающий  $X \cdot Y$  объединяя множества состояний  $\mathcal{A}$  и  $\mathcal{B}$  так, что  $q_0 = q_0^A, q_F = q_0^B, F = \{q_F\}$ . Опять получили автомат с единственным принимающим состоянием.

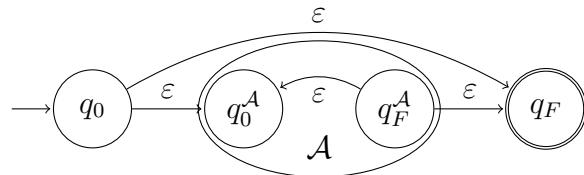
**Упражнение 1.** Доказать, что построенный автомат распознаёт язык  $X \cdot Y$ .

Для построения языка  $X|Y$  используем следующую конструкцию:



**Упражнение 2.** Доказать, что построенный автомат распознаёт язык  $X|Y$ .

И наконец перейдём к построению автомата для языка  $X^*$ :



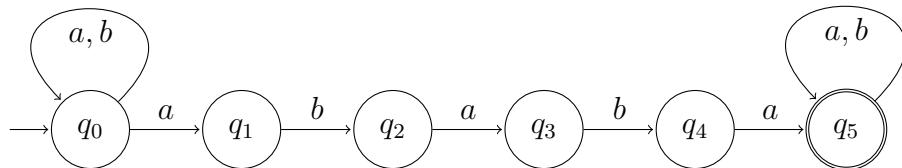
**Упражнение 3.** Доказать, что построенный автомат распознаёт язык  $X^*$ .

**Задача 1.** Постройте НКА по регулярному выражению  $a((a|b)a)^*$ .

**Задача 2.** Постройте по НКА, полученному в предыдущей задачи, ДКА.

## 2 Распознавание текстов

С помощью НКА можно легко описать язык, в который входят все слова, содержащие в качестве подслова некоторое слово. Например, следующий автомат распознаёт слова, содержащие подслово *ababa*.



**Задача 3.** Постройте по НКА, полученному в предыдущей задачи, ДКА.

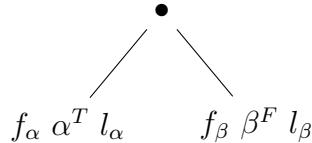
**Задача 4\* .** Докажите, что по НКА данного вида  $(\Sigma^* w \Sigma^*)$  можно построить ДКА, число состояний которого не превосходит  $|w| + 1$ .

**Задача 5.** Постройте НКА, распознающий слова, в которых есть хотя бы одно из подслов  $abab, abb, aba$ .

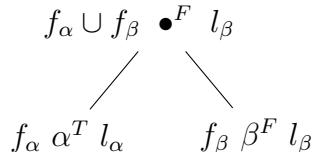
**Задача 6\*.** Постройте по НКА из предыдущей задачи ДКА. Что можно сказать об оценке числа состояний для ДКА?

### 3 О построении ДКА по РВ

На семинаре мы изучили алгоритм построения ДКА по РВ. На первом этапе мы строили дерево и вычисляли значения атрибутов  $firstpos$ ,  $lastpos$  и  $nullable$ . Принцип вычисления этих атрибутов состоит в том, что имея значение атрибутов в дочерних узлах, мы можем вычислить атрибуты самого узла. Например для узла



атрибуты узла • будут



потому что регулярное выражение  $\alpha \cdot \beta$  порождает слово  $w = uv$ , такое что РВ  $\alpha$  порождает  $u$ , РВ  $\beta$  порождает  $v$ , при этом слово  $u$  может быть пустым, а слово  $v$  – нет. Отсюда, если  $u \neq \varepsilon$ , то  $w$  начинается с тех же символов, что и  $u$ , а значит  $f_\alpha \subseteq f_\bullet$ , а если  $u = \varepsilon$ , то  $w$  начинается с тех же символов, что и слово  $v$ , поэтому  $f_\beta \subseteq f_\bullet$ , отсюда  $f_\bullet = f_\alpha \cup f_\beta$ . Поскольку слово  $w$  имеет непустой суффикс  $v$ , порождённый  $f_\beta$ , то  $l_\bullet = l_\beta$ .

**Упражнение 4.** Найти алгоритм вычисления атрибутов во всех остальных случаях для узлов с операциями • и |. Если не получается придумать алгоритм, его можно найти в книге Серебрякова. Доказать корректность вычисления атрибутов.

**Задача 7\* .** Мы рассматривали алгоритм построения ДКА по РВ, в котором не встречается пустое слово. В случае когда оно встречается, исходное РВ  $R$  может быть преобразовано либо в выражение  $R'$ , либо в выражение  $R' | \varepsilon$ , где в выражение  $R'$  пустое слово уже не входит. Предложите алгоритм, который осуществляет такое преобразование.

**Задача 8\* .** Мы рассматривали алгоритм построения ДКА по РВ, в котором не встречается пустое множество. В случае когда оно встречается, исходное РВ  $R$  может быть преобразовано либо в выражение  $R'$ , либо в выражение  $R' | \varepsilon$ , причём пустое множество и пустое слово в выражение  $R'$  не входят. Предложите алгоритм, который осуществляет такое преобразование.

**Указание:** Введите новый атрибут в дерево.