

РЕГУЛЯРНЫЕ ВЫРАЖЕНИЯ КАК КОНЕЧНЫЕ АВТОМАТЫ

Регулярные выражения это актуальный инструмент, нашедший применение во многих языках программирования. Их классическая реализация основана на конечных автоматах, где на первом этапе выражение преобразуется в эквивалентный КА. Рассмотрим часть этого алгоритма, где выражение преобразуется в эквивалентный недетерминированный конечный автомат (НКА). Как утверждает первая часть теоремы Клини, для каждого регулярного выражения существует эквивалентный, то есть принимающий тот же язык (множество символьных последовательностей), конечный автомат [1]. Мы будем использовать наиболее интуитивно понятное представление конечного автомата – граф переходов, где состояниям соответствуют вершины, а переходы представлены в виде ребер.

Автомат, эквивалентный выражению, состоящему из некоего символа, имеет две вершины-состояния: s_0 (начальное) и s_F (конечное), а также дугу-переход от s_0 к s_F с соответствующим символом. Рассмотрим на примере выражения d .

Пусть A и B – конечные автоматы, эквивалентные выражениям R_1 и R_2 соответственно. Начальные состояния у них a_0 и b_0 , конечные – a_F , b_F . Эпсилон-переходом называется переход, который может быть выполнен автоматом самопроизвольно, без входного символа. Тогда основные операторы, используемые в регулярных выражениях, определяются для эквивалентных автоматов следующим образом:

– объединение: Автомат C , эквивалентный R_1R_2 , включает A и B , с начальным состоянием a_0 , эпсилон-переходом из a_F в b_0 (рисунок 1).




Рисунок 1 – Автомат для выражения bd

– конкатенация: Автомат C , эквивалентный R_1R_2 , включает A и B , с новым начальным состоянием c_0 , новым конечным состоянием c_F и эпсилон-переходами от c_0 к a_0 и b_0 , а также от a_F и b_F к c_F (рисунок 2).

– замыкание Клини: Автомат C , эквивалентный R_1^* , включает A с новым начальным состоянием c_0 и новым конечным состоянием

cF, эпсилон-переходами от c0 к a0 и cF, и от aF к a0, а также от aF к cF (рисунок 2).




Рисунок 2 – Автомат для выражения $(bd)|(a^*)$

Займемся удалением эпсилон-переходов. Для начала все состояния, в которые существуют только эпсилон-переходы, удаляются (рисунок 3).




Рисунок 3 – Демонстрация на примере автомата с рисунка 2

Для более сложных случаев применяется другой подход. Пусть a и b – узлы, между которыми существует эпсилон-переход (рисунок 4). Необходимо:

- найти все переходы из b;
- продублировать их, добавив аналогичные переходы из a;
- удалить эпсилон-переход;
- обозначить состояние b как начальное, если таковым является a;
- обозначить состояние a как конечное, если таковым является b;




Рисунок 4 – Демонстрация на примере автомата с рисунка 3

В ходе проделанной работы мы изучили алгоритм преобразования регулярного выражения в НКА, этого достаточно для реализации регулярных выражений. На практике обычно добавляют еще один шаг с преобразованием НКА в детерминированный автомат, который более прост для программной реализации, но в данной работе этот шаг избыточен.

ЛИТЕРАТУРА

1. М. Ниват. Regular expressions into finite automata //Theoretical Computer Science – Is. 120.–Великобритания: Lsevier, 1993.