

一、 工具说明

本工具是用来计算正则表达式的五个属性: 是否可空(Nullable)、First 集、Last 集、FollowLast 集合和 Flexible 属性。

计算方法在./src/main/java/cn/ac/ios/TreeNode/TreeNode.java 中的 calculateFiveAttributesNullableAndFirstAndLastAndFlexibleAndFollowLast 函数。主函数也在 TreeNode.java 中。

二、 使用方法为:

在 TreeNode.java 中修改 String regex = "...", 然后执行即可

例如 String regex = "(\d+[abc]+)+";

```
public static void main(String[] args) throws InterruptedException {
    String regex = "(\\d+[abc]+)+";
    TreeNode treeNode = createReDoSTree(regex);
    printTree(treeNode);
    treeNode.calculateFiveAttributesNullableAndFirstAndLastAndFlexibleAndFollowLast();
    System.out.println(treeNode.isNullable());
    System.out.println(treeNode.getFirst());
    System.out.println(treeNode.getLast());
    System.out.println(treeNode.getFollowLast());
    System.out.println(treeNode.isFlexible() + " " + treeNode.getdFlexible());
}
```

输出结果为:

```
'- (\d+[abc]+)+
  |- (\d+[abc]+)
    | |- (
      | |- \d+[abc]+
        | | |- \d+
          | | | |- \d
            | | | ' - +
              | | ' - [abc]+
                | | | |- [abc]
                  | | | |- [
                    | | | | |- a
                      | | | | |- b
                        | | | | |- c
                          | | | | ' - ]
                            | | | ' - +
                              | ' - )
                                ' - +


false
[0, 1, 2, 3, 4, 5, 6, 7, 8, 9]
[a, b, c]
[a, b, c, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9]
true -1.0
```

其中多叉树为对正则表达式 $r = (\backslash d+[abc])+$ 经过 ANTLR 工具解析得到的语法树。

而后五行分别为：

- (1) r 是否为可空的 (Nullable)
- (2) r 的 first 集
- (3) r 的 last 集
- (4) r 的 followLast 集
- (5) r 的 bFlexible 属性、dFlexible 属性

其中 ANTLR 支持多种语言的解析，包括 PCRE、Python、Java、JavaScript，对应语法文件在相应的文件夹中，例如 Java 的语法树文件在 JavaRegex 中



三、 已支持的正则表达式形式：

Definition 2. Real-world Regular Expression (regex). A regex over Σ is a well-formed parenthesized formula, consisting of operands in $\Sigma^* \cup \{\backslash i \mid i \geq 1\}$ ³. Besides the common rules governing standard regular expressions (e.g. $r_1|r_2, r_1r_2, r_1\{m, n\}$ defined in Definition 1), a regex also has the following constructs: (i) capturing group (r) ; (ii) non-capturing group $(?:r)$; (iii) lookarounds: positive lookahead $r_1(?:=r_2)$, negative lookahead $r_1(?:!r_2)$, positive lookbehind $(?:<=r_2)r_1$, and negative lookbehind $(?:<!r_2)r_1$; (iv) anchors: Start-of-line anchor $^$, End-of-line anchor $$$, word boundary $\backslash b$, and non-word boundary $\backslash B$; (v) lazy quantifiers: $r??$, $r*?$, $r+?$, and $r\{m, n\}?$; and (vi) backreference $\backslash i$.

本工具支持上述定义 2 中除了反向引用的所有形式,例如`[^abc]`, `[\d\w]`, `\S`, `^abc$`, `(?=a)\w+`, `a++`, `\w{2,4}`, `(?:xyz)`等等

四、 特别说明

1. 本工具默认使用 `java` 语法树进行解析, 如需更换, 可通过调用 `createReDoSTree` 函数来传入语言。
2. 对于特殊字符“.”, 在正则表达式中代表除`\r`和`\n`外的任意字符, 工具为了对此符号进行了优化。具体为: 若表达式中含有补集类符号, 如`[^abc]`, `\S`, `\W`, 则全集定义为`{正则表达式中出现的字符} ∪ {字母数字下划线} ∪ {感叹号}`。例如 `r = "[^a-z]"` 的 `first` 集、`last` 集、`followLast` 集为:

```
[!, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F, G, H, I, J, K, L, M, N, O, P, Q, R, S, T, U, V, W, X, Y, Z, _]  
[!, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F, G, H, I, J, K, L, M, N, O, P, Q, R, S, T, U, V, W, X, Y, Z, _]  
[]
```

此优化体现在函数 `calculateFiveAttributesNullableAnd`

`FirstAndLastAndFlexibleAndFollowLast` 的开头部分, 如下图。



```
2251 if (rootAlphabet.isEmpty()) {  
2252     // 为处理补结点的问题, 首先获取树的字母表Σ, getLetterSet(true)  
2253     TreeNode treeNodeCopy = SerializationUtils.clone( object: this);    // 深拷贝  
2254     // 去补  
2255     removeNegateSymbol(treeNodeCopy, Constant.SimpleLevel.HIGH);  
2256     // 删除零宽断言  
2257     deleteZeroWidthAssertion(treeNodeCopy);  
2258     // 使用重写后的去首尾^$  
2259     treeNodeCopy.deleteCaretAndDollarSymbols();  
2260     // 新版重写空串  
2261     treeNodeCopy = removeBlankStr(treeNodeCopy);  
2262     treeNodeCopy.removeBlankStr();  
2263     // 重写反向引用后 删除NonCapturingGroupFlag ?:  
2264     treeNodeCopy.deleteNonCapturingGroupFlag();  
2265  
2266     rootAlphabet = treeNodeCopy.getLetterSet( addDefaultw: true, repairBackSlashElements: true);  
2267 }  
2268
```

若注释掉这一部分, 则全集默认为 `unicode` 字符集 (65536 个字符)。

3. 对于 `lookaround` 的处理, 目前为直接定义为无效值 (空集), 这是一个需要优化的点。