

Практическое задание №1. Осень 2024

Введение

Регулярные выражения – мощный инструмент для обработки текстовых данных, включая тексты на естественных языках. Регулярные выражения используются в различных задачах, таких как предварительная обработка данных, системы интеллектуального анализа информации на основе правил, сопоставление с образцом, разработка текстовых функций, валидация входных данных, извлечение данных из интернета, и т. д. Однако не каждую NLP задачу целесообразно решать с помощью регулярных выражений.

Данное задание разбито на две части: задачи первой части можно (и, пожалуй, нужно) решать с помощью регулярных выражений, а вот задачи второй части либо по определению невозможно решить, используя только регулярные выражения, либо сложность выражения настолько велика, что их применение нецелесообразно.

Постановка задачи

Часть 1.

Требуется составить регулярные выражения, для решения следующих независимых подзадач:

- проверка корректности пароля;
- проверка корректности web цвета;
- токенизация математического выражения;
- проверка корректности даты.

1.1. Проверка корректности пароля

В рамках этой подзадачи требуется разработать регулярное выражение, которым возможно проверить, может ли являться входная строка (целиком) корректным паролем.

Ограничения на пароли:

- пароль должен содержать только латинские символы, цифры и специальные символы ^\$%#@#&*!?
- пароль должен состоять из не менее чем восьми символов
- пароль должен содержать по крайней мере один латинский символ в верхнем регистре
- пароль должен содержать по крайней мере один латинский символ в нижнем регистре
- пароль должен содержать по крайней мере одну цифру
- пароль должен содержать по крайней мере два различных специальных символа
- пароль не должен содержать двух одинаковых символов подряд

Примеры корректных паролей:

- rtG3FG!Tr^e
- aA1!*!Aa
- oF^a1D@y5eb
- enroi#\$rkdeR#\$092uwedchf34tguv394h

Примеры некорректных паролей:

- пароль
- password
- qwerty
- IOngPa\$\$W0Rd

1.2. Проверка корректности web цвета

В рамках этой подзадачи требуется разработать регулярное выражение, которым возможно проверить, может ли являться входная строка (целиком) корректной записью цвета в одном из трёх web форматов:

- **rgb**: `rgb(r, g, b)`, где «r, g, b» - это комбинация из трёх целых чисел (от 0 до 255) или трёх процентных значений (от 0% до 100%), перечисленных через запятую.
- **hex** (шестнадцатеричный код цвета, `#rrggbb`) – это шестизначное представление цвета в RGB пространстве. Первые две цифры (rr) – представляют собой красное значение,

следующие две – зелёное значение (gg), а последние – синее значение (bb). Перед значениями каналов предшествует символ #. Также допускается сокращённый вид записи – по одной цифре – #rgb

- **hsl** (тон, насыщенность и светлота, $hsl(h, s, l)$) - записывается похожим на rgb форматом образом. Тон – целое число в диапазоне от 0 до 360, насыщенность и светлота – целочисленные процентные значения.

Примеры корректных цветов:

- #21f48D
- #888
- rgb(255, 255, 255)
- rgb(10%, 20%, 0%)
- hsl(200, 100%, 50%)
- hsl(0, 0%, 0%)

Примеры некорректных цветов:

- #2345
- ffffff
- rgb(257, 50, 10)
- hsl(20, 10, 0.5)
- hsl(34%, 20%, 50%)

1.3. Токенизация математического выражения

Целью данной подзадачи является создание регулярного выражения, способного разбить строку, содержащую математическое выражение, на токены (элементарные части) и определить тип этих токенов. Математическое выражение может состоять из следующих элементов:

- **переменная (тип variable)** – строка из латинских букв, цифр и символа нижнего подчёркивания (_), начинающаяся не с цифры: a, var123, some_var_name;
- **число (тип number)** – строка, являющаяся целым или вещественным числом в общей форме без знака (в качестве разделителя целой и дробной части – точка): 42, 123456789, 23.567, 0.6734537
- **константа (тип constant)** – строка из списка: pi, e, sqrt2, ln2, ln10
- **функция (тип function)** – строка из списка: sin, cos, tg, ctg, tan, cot, sinh, cosh, th, cth, tanh, coth, ln, lg, log, exp, sqrt, cbrt, abs, sign
- **операция (тип operator)** – строка из списка ^, *, /, -, +
- **круглые скобки (тип left_parenthesis и right_parenthesis)**

Токены выражения могут отделяться друг от друга произвольным количеством пробелов (возможно, нулевым). Выделять пробельные символы в токены не нужно. Названия переменных не могут совпадать с именами функций и констант.

Примеры выражений и ожидаемых токенов:

- **выражение:** "sin(x) + cos(y) * 2.5"

токены:

```
{"type": "function", "span": [0, 3]},  
{"type": "left_parenthesis", "span": [3, 4]},  
{"type": "variable", "span": [4, 5]},  
{"type": "right_parenthesis", "span": [5, 6]},  
{"type": "operator", "span": [7, 8]},  
{"type": "function", "span": [9, 12]},  
{"type": "left_parenthesis", "span": [12, 13]},  
{"type": "variable", "span": [13, 14]},  
{"type": "right_parenthesis", "span": [14, 15]},  
{"type": "operator", "span": [16, 17]},  
{"type": "number", "span": [18, 21]}
```

- **выражение:** "pi + us05NlMvU"

токены:

```
{"type": "constant", "span": [0, 2]},  
{"type": "operator", "span": [6, 7]},  
{"type": "variable", "span": [15, 24]}
```

- выражение: "(63393394.98 /8505)"

токены:

```
{"type": "left_parenthesis", "span": [0, 1]},  
 {"type": "number", "span": [10, 21]},  
 {"type": "operator", "span": [22, 23]},  
 {"type": "number", "span": [23, 27]},  
 {"type": "right_parenthesis", "span": [33, 34]}
```

1.4. Проверка корректности даты

Требуется разработать регулярное выражение, способное определить, является ли входная строка (целиком) датой в одном из нескольких форматов. Допускаются следующие форматы даты:

- **день.месяц.год** (14.09.2023, 5.02.1995, 01.4.2012)
- **день/месяц/год** (14/09/2023, 5/02/1995, 01/4/2012)
- **день-месяц-год** (14-09-2023, 5-02-1995, 01-4-2012)
- **год.месяц.день** (2023.09.14, 1995.02.5, 2012.4.01)
- **год/месяц/день** (2023/09/14, 1995/02/5, 2012/4/01)
- **год-месяц-день** (2023-09-14, 1995-02-5, 2012-4-01)
- **день_месяц_rus год** (14 сентября 2023, 5 февраля 1995, 01 апреля 2012)
- **Месяц_eng день, год** (September 14, 2023, February 5, 1995, April 01, 2012)
- **Мес_eng день, год** (Sep 14, 2023, Feb 5, 1995, Apr 01, 2012)
- **год, Месяц_eng день** (2023, September 14, 1995, February 5, 2012, April 01)
- **год, Мес_eng день** (2023, Sep 14, 1995, Feb 5, 2012, Apr 01)

Примеры корректных дат:

- 20 января 1806
- 1924, July 25
- 26/09/1635
- 3.1.1506

Примеры некорректных дат:

- 25.08-1002
- декабря 19, 1838
- 8.20.1973
- Jun 7, -1563

Примечание: год должен быть неотрицательным.