




Regularni iskazi (RegExp)

Predmet: Administriranje Baze Podataka
Predavač: dr Dušan Stefanović

REGULARNI SKAZI



RegExp definicija

predstavljaju specijalan tekstualni niz koji definiše obrazac (šablon, uzorak) za pretragu ili validaciju podataka



Fleksibilnost

Za razliku od wildcard izraza, regularni izrazi su fleksibilniji i omogućavaju preciznije definisanje složenih obrazaca



Efikasnost

Pretraga pomoću regularnih izraza je efikasna jer se rezultati dobijaju već tokom jednog prolaza kroz podatke.




Validacija podataka

Validacija formata podataka kao što su e-mail adrese, brojevi telefona.



Pronalaženje informacija




Pronalaženje specifičnih informacija u tekstu ili bazama podataka.




Zamena sadržaja

Zamena sadržaja koji odgovara određenom obrascu.

REGULARNI SKAZI - PRETRAGA



FSM – PRIMER PREPOZNAVANJA REGULARNOG IZRAZA abc



Karakteristika	Opis
Konačan broj stanja	FSM ima tačno određena stanja kroz koja može da se kreće
Deterministički prelazi	Za svaki ulaz i trenutno stanje postoji tačno jedno naredno stanje
Ulaz se čita sekvencijalno	FSM čita jedan simbol po jedan — ne vraća se unazad
Prihvatajuća stanja	FSM označava da li ulazni niz odgovara pravilima
Jednostavna logika	Sve odluke se zasnivaju na trenutnom stanju + sledeći simbol

OSOBINE REGEXP Patern (^)

REGEXP **nije case sensitive**, osim ukoliko se koristi **binary** string.

MySQL upit prikazuje imena studenata čija imena počinju sa 'k'.

'^' se koristi za mečovanje početka imena.

```
SELECT *  
FROM Student  
WHERE Ime REGEXP '^k';
```

MySql iskaz prikazuje imena studenata koja počinju sa 'k' vodeći računa o malim tj. velikim slovima jer se koristi **BINARY** operator.

```
SELECT *  
FROM Student  
WHERE Ime REGEXP BINARY '^k';
```

OSOBI NE REGEXP

Patern (\$)

MySql iskaz pronalazi imena studenata čija se imena završavaju na 'on'.
'\$' se koristi za mečovanje završetka stringa.

```
SELECT *  
FROM Student  
WHERE Ime REGEXP "on$";
```

MySql iskaz pronalazi autore čija imena sadrže 't' u imenu.

```
SELECT *  
FROM Student  
WHERE Ime REGEXP "t";
```

OSOBINE REGEXP

Patern ([...])

MySQL iskaz pronalazi imena studenata koja sadrže sledeća slova u imenu 'z' ili 'v' ili 'm'.

```
SELECT *  
FROM Student  
WHERE Ime REGEXP "[zvm]";
```

MySQL iskaz pronalazi imena studenata koja sadrže karaktere od b do g

```
SELECT *  
FROM Student  
WHERE Ime REGEXP "[b-g]" ;
```

OSOBINE REGEXP Patern (.) i ({...})

MySql iskaz pronalazi imena studenata koja sadrže tačno 12 karaktera. Koristi se **‘^’** i **‘\$’** podudaranje za početak i kraj imena i **12 instanci ‘.’** za podudaranje sa 12 karaktera.

Tačka (.) je patern koji odgovara jednom bilo kom karakteru

```
SELECT *
FROM Student
WHERE Ime REGEXP '^.....$';
```

MySql iskaz pronalazi imena studenata koja sadrže tačno 12 karaktera. Koristi se **‘^’** i **‘\$’** podudaranje za početak i kraj imena i instanca **‘.’**. Srednje zagrade **{}** za definisanje koliko puta se tačka ponavlja.

```
SELECT * FROM Student
WHERE Ime REGEXP '^.{12}$';
```

OSOBBINE REGEXP Paterni

Patern	Šta patern mečuje
^	Početak stringa
\$	Kraj stringa
.	Jedan bilo koji karakter
[...]	Bilo koji karakter koji se nalazi u uglastim zagradama
[^...]	Bilo koji karakter koji se ne nalazi u uglastim zagradama
p1 p2 p3	Alternativa; mečuje ili p1 ili p2 ili p3 patern
*	Nula ili više instanci prethodnog elementa
+	Jedna ili više instanci prethodnog elementa
{n}	n instanci prethodnog elementa
{m,n}	m do n instanci prethodnog elementa

Podudaranje po tipu klase

POSIX Klasa

Opis mečovanja

<code>[:alnum:]</code>	Alfanumerički znakovi (slova ili brojevi). Odgovara <code>[a-zA-Z0-9]</code>
<code>[:alpha:]</code>	Bilo koje slovo. Odgovara <code>[a-zA-Z]</code>
<code>[:blank:]</code>	Space i tabulator. Odgovara <code>[\t]</code>
<code>[:cntrl:]</code>	ASCII kontrolni karakteri (npr. <code>\n</code> , <code>\r</code> , <code>\0</code>)
<code>[:digit:]</code>	Cifre. Odgovara <code>[0-9]</code>
<code>[:graph:]</code>	Bilo koji karakter osim whitespace (space, tab)
<code>[:lower:]</code>	Mala slova. Odgovara <code>[a-z]</code>
<code>[:punct:]</code>	Interpunkcijski znakovi (npr. <code>.</code> , <code>!</code> , <code>?</code> , <code>;</code> , <code>-</code> , <code>_</code>)
<code>[:space:]</code>	Bilo koji razmak (space, tab, newline, carriage return...)
<code>[:upper:]</code>	Velika slova. Odgovara <code>[A-Z]</code>
<code>[:xdigit:]</code>	Hexadecimalne vrednosti. Odgovara <code>[0-9A-Fa-f]</code>

Napomena:

POSIX klase (`[:alpha:]`, `[:digit:]`,...) funkcionišu u MySQL, grep, awk, ali ne u JavaScript, Python, ...

```
SELECT * FROM Zemlje where Ime regexp '[:blank:]'
```

Escape Sekvenca

Želimo da pretražimo oznaku CD modela [7543], problem je što se uglaste zagrade koriste i za podudaranje karaktera koji se nalaze u uglastim zgradama.

Escape sekvencu koristimo ukoliko želimo da mećujemo same uglaste zagrade a ne njenu REGEXP sintaksu.

```
SELECT *  
FROM Proizvod  
WHERE Ime_proivoda REGEXP 'CD-RW Model \[7543\]';
```

Repetition Match

Koristi se kada želimo da mećujemo ponavljanje određene instance više puta

Patern	Opis
*	Nula ili više instanci prethodnog elementa
+	Jedna ili više instanci prethodnog elementa
{n}	n instanci prethodnog elementa
{n,}	minimum n instanci prethodnog elementa
{n1,n2}	Minimum n1 a maksimum n2 instance
?	Nula ili jedna instanca prethodnog elementa

```
SELECT *
FROM product
WHERE opis REGEXP 'Drives?';
```


kod	ime	opis
3	WildTech 250Gb 1700	SATA Disk Drive
20	MasterSlave Multi-pack	5 SATA Disk Drives

Podudaranje na osnovu pozicije u tekstu

Patern	Opis
^	Početak teksta
\$	Kraj teksta
[[:<:]]	Početak reči
[[:>:]]	Kraj reči

```
SELECT ime
FROM Proizvod
WHERE ime REGEXP '[[:<:]]One[[:>:]]';
```

OSOBINE REGEXP



Za mečovanje kompleksnih iskaza tj paterna potrebno je razumeti tri simbola koja se koriste kod REGEXP (zagrada, \$(mečuje kraj stringa) i ^ (mečuje početak stringa))

Postoje tri vrste zagrada


`[]` -> definišu karaktere koje treba mečovati

`{}` -> definišu koliko karaktera treba mečovati

`()` -> koriste se za grupisanje

Šta odgovara sledećem regexp-u

```
^[a-zA-Z0-9]{1,10}@[a-zA-Z]{1,10}\.(com|org)$
```



Primeri koji odgovaraju izrazu:

pera123@domen.com

ANA9@abcORG.org

x@a.com

Primeri koji ne odgovaraju:

pera@domen.rs (ne završava se sa com ili org)

pera1234567890@abc.com (korisničko ime duže od 10 znakova)

ime@123.com (domen sadrži cifre – nije dozvoljeno ovim izrazom)

ime@a.b.com (nema podršku za poddomene)

PRIMERI

1. Mečuj karakter između a-g bilo gde u iskazu

$[a-g]$

2. Mečuj karaktere između a-g sa dužinom 3. Potrebno je definisati dužinu validacije

$[a-g]\{3\}$

$^[a-g]\{3\}\$$ -> dozvoljavamo samo tri bilo koja slova iz opsega a-g u iskazu

3. Mečuj karaktere između a-g sa minimum 1 karakterom a maximum 3

$^[a-g]\{1,3\}\$$

4. Mečovanje 8 digita fiksne dužine (npr 12345678)

$^[0-9]\{8\}\$$

5. Mečovanje minimum 3 a maksimalno 7 digita

$^[0-9]\{3,7\}\$$

6. Mečovanje računa gde su prva tri karaktera tekstualna a naredna 8 su brojevi

$^[a-zA-Z]\{3\}[0-9]\{8\}\$$

7. Prosta validacija web adrese

$^[w]\{3\}\.[A-Za-z0-9]\{1,12\}\.(com|edu|rs)$

PRIMERI

1. Napisati REGEXP koji pronalazi mala slova, cifre, donju i srednju crtu. Dozvoljen broj karaktera je između 3 i 16.

`^[a-z0-9_-]{3,16}$`

2. Prikaz hekso vrednosti sa '#' opcionim karakterom i sa mogućnošću da se prikažu 6 ili 3 hekso vrednosti.

`^#?([a-f0-9]{6}|[a-f0-9]{3})$`

PRIMERI

Pretraga email adrese

$$^([a-z0-9_\\-]+)@([\\da-z\\-]+)\\.([a-z\\.]{2,6})\$$$

Redni broj	Opis regularnog izraza
$^$	Početak stringa
$([a-z0-9_\\-]+)$	Korisničko ime: mala slova, cifre, donja crta, tačka, crtica (jedan ili više puta)
$@$	Obavezni znak '@'
$([\\da-z\\-]+)$	Domen: cifre, mala slova, tačka, crtica (jedan ili više puta)
$\\.$	Obavezna tačka između domena i TLD-a
$([a-z\\.]{2,6})$	TLD: mala slova i tačka, dužina 2 do 6 karaktera
$\$$	Kraj stringa

PRIMERI

Pretraga web adrese

$$^(\text{https?:\\V})?([\da-z\-.]+)\.([a-z\.]{2,6})([\\w \-.]*)*\\/?\$$$

Deo izraza	Značenje
$^$	Početak stringa
$(\text{https?:\\V})?$	Opcioni protokol http:// ili https://
$([\da-z\-.]+)$	Domen (npr. www, google, example123) — dozvoljene su cifre, mala slova, tačka i crtica
$\.$	Obavezna tačka pre TLD-a
$([a-z\.]{2,6})$	TLD (npr. com, org, co.uk) — 2 do 6 malih slova ili tačaka
$([\\w \-.]*)^*$	Putanja: opciona deo koji sadrži /, reči, razmake, tačke i crtice, i može da se ponavlja
$/?$	Opciona završni /
$\$$	Kraj stringa