

Регуларни изрази

материјал прилагођен за 2012/13 шк. год.

Објекат класе `Scanner` користи регуларне изразе како би у улазном току препознавао и издвајао целе бројеве, реалне бројеве, вредности типа `boolean`, ..., као и неке нестандартне токене које ми сами описујемо регуларним изразима.

Регуларни израз се дефинише објектом класе `String` или класе `Pattern (java.util.regex.Pattern)`, који представља компајлирану репрезентацију регуларног израза.

Карактери који у регуларном изразу имају специјално значење називају се метакарактерима. То су:

`<([{\^-= $!|})? *+. >`

Остали карактери унутар регуларног израза представљају сами себе.

Тако нпр. регуларни израз `"oor"` одговара баш стрингу `"oor"` јер ни `o` ни `r` нису метакарактери.

<code>\\</code>	backslash <code>\</code>
<code>\t</code>	табулатор
<code>\n</code>	line feed
<code>\r</code>	carriage-return

Ако је потребно упаривање са неким од метакарактера, испред њега се наводи backslash.

Нпр. унутар `String`-литерала писаћемо `\\.` на месту где очекујемо баш тачку, односно `\\(` (тамо где очекујемо `(`, док уколико се регуларни израз учитава нпр. са стандардног улаза или из фајла, тамо се пише `\.` односно `\(`.

Карактерске класе

<code>[abc]</code>	одговара било ком од карактера наведених унутар заграда <code>[]</code> (овде: <code>a</code> , <code>b</code> или <code>c</code>)
<code>[^abc]</code>	било који карактер осим <code>a</code> , <code>b</code> или <code>c</code> (негација)
<code>[a-zA-Z]</code>	било шта од <code>a</code> до <code>z</code> или од <code>A</code> до <code>Z</code> , укључујући и <code>a</code> , <code>z</code> , <code>A</code> , <code>Z</code> (опсег)

Унутар карактерске класе важи другачији скуп метакарактера.

Нпр. тачка `tu` губи своје специјално значење, док `ga` - добија (означава опсег).

<code>[. ,]</code>	тачка, бланко или запета
----------------------	--------------------------

Логички оператори

<code>^</code>	негација
<code> </code>	или
<code>&&</code>	и

`[a-z&&[def]]` – `d`, `e` или `f`, јер: (од `a` до `z`) и (`d`, `e` или `f`)

`[a-z&&[^aeiou]]` – сугласник, јер: (од `a` до `z`) и (није ниједан од: `a`, `e`, `i`, `o`, `u`).

Предефинисане карактерске класе

<code>.</code>	било који карактер (подразумевано осим line separator-a, а са флегом <code>DOTALL</code> укључујући line separator)
<code>\d</code>	цифра <code>[0-9]</code>
<code>\D</code>	било који карактер који није цифра <code>[^0-9]</code>
<code>\s</code>	белина <code>[\t\n\x0B\f\r]</code>
<code>\S</code>	било који карактер који није белина <code>[^\s]</code>
<code>\w</code>	слово, подвлака или цифра <code>[a-zA-Z_0-9]</code>
<code>\W</code>	било који карактер који није ни слово ни подвлака ни цифра <code>[^\w]</code>

Када се у регуларни израз укључују секвенце које почињу обрнутом косом цртом `\` (backslash), како Јава унутар `String`-литерала третира backslash као почетак escape секвенце, backslash унутар регуларног израза који се задаје `String`-литералом мора се писати као `\\`

Границе

<code>^</code>	почетак линије (подразумевано улаза, а са флегом <code>MULTILINE</code> сваке линије)
<code>\$</code>	крај линије (подразумевано улаза, а са флегом <code>MULTILINE</code> сваке линије и улаза)
<code>\b</code>	граница речи
<code>\B</code>	није граница речи
<code>\A</code>	почетак улаза
<code>\G</code>	крај претходног упаривања
<code>\z</code>	крај улаза

Када се у регуларни израз укључују секвенце које почињу обрнутом косом цртом `\` (backslash), како Јава унутар `String`-литерала третира backslash као почетак escape секвенце, backslash унутар регуларног изрази који се задаје `String`-литералом мора се писати као `\\`

Квантификатори (похлепни покушавају да упаре што дужи, шкрти што краћи део улаза, а посесивни читав улаз)

похлепни	шкрти	посесивни	
<code>X?</code>	<code>X??</code>	<code>X?+</code>	<code>X</code> једном или ниједном (опционо <code>X</code>)
<code>X*</code>	<code>X*?</code>	<code>X*+</code>	<code>X</code> нула или већи број пута
<code>X+</code>	<code>X+?</code>	<code>X++</code>	<code>X</code> једном или више пута
<code>X{n}</code>	<code>X{n}?</code>	<code>X{n}+</code>	<code>X</code> тачно <code>n</code> пута
<code>X{n,}</code>	<code>X{n,}?</code>	<code>X{n,}+</code>	<code>X</code> бар <code>n</code> пута
<code>X{n,m}</code>	<code>X{n,m}?</code>	<code>X{n,m}+</code>	<code>X</code> бар <code>n</code> , али не више од <code>m</code> пута

Capturing group и back reference

(`X`) подизраз (capturing group). Касније у изразу се може реферисати на њега коришћењем тзв. back reference: `\n` где је `n` индекс групе и одређује се бројањем заграда (у регуларном изразу које претходе `X`-у. Броји се од 1. Читав израз је такође једна група, а њен индекс је 0. Нпр. регуларни израз `(\d\d)\1` описује произвољне две цифре за којима следе те две исте цифре

Приликом упаривања улаза са регуларним изразом бивају сачуване секвенце са улаза упарене са сваком од група у изразу. Овим секвенцама могуће је приступити након што се операција упаривања успешно заврши.

Line terminator

Подразумевано, било шта од следећег препознаје се као line terminator:

<code>'\n'</code>	newline (line feed)
<code>"\r\n"</code>	carriage-return за којим непосредно следи line feed
<code>'\r'</code>	carriage-return
<code>'\u0085'</code>	next-line
<code>'\u2028'</code>	line-separator
<code>'\u2029'</code>	paragraph-separator

док, уколико се користи флер `UNIX_LINES`, као line terminator препознаје се само `'\n'`.

Употреба флегова

Осим `DOTALL`, `MULTILINE` и `UNIX_LINES`, постоје и други флегови: `CANON_EQ`, `CASE_INSENSITIVE`, `COMMENTS`, `LITERAL`, `Unicode_CASE`.

Уместо `String`-а са дефиницијом регуларног изрази неопходно је користити објекат класе `Pattern` који се добија компајлирањем регуларног изрази уз навођење жељеног флега или жељене комбинације флегова. Флегови се могу комбиновати битским или (`|`) или оператором `+`.

Нпр.

```
Pattern izraz = Pattern.compile(".{3}", Pattern.DOTALL);
Pattern izraz1 = Pattern.compile("^C", Pattern.CASE_INSENSITIVE+Pattern.MULTILINE);
Pattern izraz2 = Pattern.compile("^C", Pattern.CASE_INSENSITIVE|Pattern.MULTILINE);
Scanner sc = new Scanner("a\nb\ncd");
System.out.println("'" + sc.findWithinHorizon(izraz, 0) + "'");
System.out.println(sc.findWithinHorizon(izraz1, 0));
// ⇔ System.out.println(sc.findWithinHorizon(izraz2, 0));
```