
Reguláris kifejezések Oracle-ben

Jánosi-Rancz Katalin Tünde

Reguláris kifejezések - *Regular Expression* - *regex*

- szövegmintákat leíró nyelv, amellyel karakterláncokban található mintákat írunk le
 - standardizált
 - minta illesztéssel nagyon gyors keresés, szűrés megvalósítására szolgál
-

-
- **Mintaillesztés:** ha ellenőrizni szeretnénk, hogy egy sztring megfelel-e bizonyos szabályoknak vagy megtalálhatók-e benne bizonyos szabályoknak eleget tévő rész sztringek
 - pl. **Valós email cím**
-

Operátor	Leírás
*	Nulla vagy több előfordulás
+	Egy vagy több előfordulás
?	Nulla vagy egy előfordulás
	Választás operator alternatív minták megadásához
^	Illeszkedés a minta elején
\$	Illeszkedés a minta végén
.	Bármilyen karakter a támogatott karakterkészletből, kivéve a NULL
[...]	Illeszkedik a listában szereplő valamelyik karakterrel.
[^ ...]	[^] karakternek speciális jelentése van, a nem illeszkedést jelenti. Illeszkedik a listában nem szereplő karakterekkel.
()	Csoportképző operátor, amelyben szereplő kifejezésre később \n alakban hivatkozhatunk, ahol n a teljes reguláris kifejezésben részkifejezés sorszáma.
{m}	Pontosan m-szeres ismétlődés.
{m,}	Legalább m-szeres ismétlődés.
{m,n}	Legalább m, de legfeljebb n-szeres ismétlődés.
\	A következő metakaraktert szószerint értelmezi, pl. \a.
\n	Többszöri előfordulás, Hivatkozás az n-edik '(' ') zárójelek közé zárt kifejezésre Az n 1 és 9 között lehet.
[..] ^f	Karakterek egy csoportja vagy egy több karakterből álló szimbólum pl.: 'ny', 'ly'
[: :] ^g	Karakterosztály megadása (pl.: [:alpha]). A karakterosztályon belül bármely karakterre illeszkedik
[==] ^h	Ekvivalens osztályok meghatározása.

Karakterosztály	Jelentés
<code>[:alnum:]</code>	Minden alfanumerikus karakter
<code>[:alpha:]</code>	Minden betű karakter
<code>[:blank:]</code>	Minden fehérrelválasztó.
<code>[:cntrl:]</code>	Minden kontroll karakter (nem nyomtatható)
<code>[:digit:]</code>	Minden numerikus szám
<code>[:graph:]</code>	<code>[:punct:]</code> , <code>[:upper:]</code> , <code>[:lower:]</code> , és <code>[:digit:]</code> karakterek.
<code>[:lower:]</code>	Minden kisbetű.
<code>[:print:]</code>	Nyomtatható karakterek.
<code>[:punct:]</code>	Írásjelek.
<code>[:space:]</code>	Minden helyköz karakter (nem nyomtatható).
<code>[:upper:]</code>	Minden nagybetű.
<code>[:xdigit:]</code>	Minden érvényes 16-os számrendszerbeli szám.

<code>\d</code>	Matches a digit character.
<code>\D</code>	Matches a nondigit character.
<code>\w</code>	Matches a word character.
<code>\W</code>	Matches a nonword character.
<code>\s</code>	Matches a whitespace character.
<code>\S</code>	matches a non-whitespace character.
<code>\A</code>	Matches the beginning of a string or matches at the end of a string before a newline character.
<code>\Z</code>	Matches at the end of a string.
<code>*?</code>	Matches the preceding pattern zero or more occurrences.
<code>+?</code>	Matches the preceding pattern one or more occurrences.
<code>??</code>	Matches the preceding pattern zero or one occurrence.
<code>{n}?</code>	Matches the preceding pattern n times.
<code>{n,}?</code>	Matches the preceding pattern at least n times.
<code>{n,m}?</code>	Matches the preceding pattern at least n times, but not more than m times.

Példák

- $abc \rightarrow abc$
- $a(b|c)d \rightarrow abd \text{ és } acd$
- $a.c \rightarrow abc, adc, a1c, a\&c, \text{ DE NEM } abb$
- $a+ \rightarrow a, aa, aaa, \text{ DE NEM } bbb$
- $ab?c \rightarrow abc, ac, \text{ DE NEM } adc, abbc$
- $ab^*c \rightarrow ac, abc, abbc, abbbbc, \text{ DE NEM } adc$
- $a\{5\} \rightarrow aaaaa, \text{ DE NEM } aaaa$
- $a\{3,\} \rightarrow aaa, aaaaa, \text{ DE NEM } aa$
- $a\{3,5\} \rightarrow aaa, aaaa, aaaaa, \text{ DE NEM } aa$

Példák


- [abc] -> at, bet, cot, DE NEM def
- [^abc] -> abcdef, ghi, DE NEM abc
- [^a-i] -> hijk, lmn, DE NEM abcdefghi
- **Subexpression**
- (abc)?def -> abcdefghi, defghi, DE NEM ghi
- **Backreference**
- (abc|def)\1 -> abcabc, defdef, de NEM abcdef, abc
- ^(.*)\1\$ -> 2 egyforma karakter egymás mellett

Példák

- `\+ -> abc+def, DE NEM abcdef`
 - `^def -> defghi, DE NEM abcdef`
 - `def$ -> abcdef, DE NEM defghi`
 - `[[[:upper:]]]+ -> abcDEFghi, DE NEM abcdefghi`
-

REGEXP_LIKE

- Karakterlánc és minta összehasonlítására alkalmas
- Hasonló a LIKE - hoz, de sokkal bonyolultabb reguláris kifejezéseket adhatunk meg



- `Regexp_like(karakterlánc, minta [, találati paraméterek])`

- 1. Steven/ Stephen.

```
SELECT name FROM emp WHERE REGEXP_LIKE (last_name, '^Ste(v|ph)en$');
```

- 2. Akinek 2 magánhangzó van a nevében, 'i' = case-insensitive

```
SELECT name FROM emp WHERE REGEXP_LIKE (last_name, '([aeiou])\1', 'i');
```

- 3. Három hosszú nevek

```
SELECT name FROM emp  
WHERE regexp_like (name, '^[a-z]{3}$' );
```

- 4. Második betű a,c vagy f

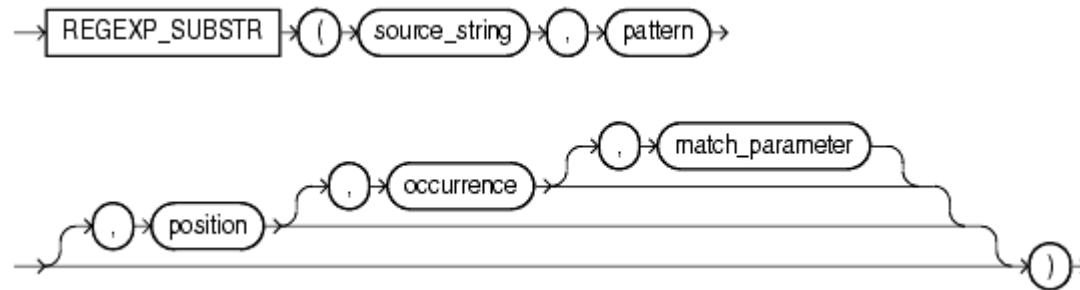
```
SELECT name FROM emp  
where REGEXP_LIKE( name, '^.[acf]' );
```

- 5. Valós email cím

```
SELECT email FROM emp  
WHERE REGEXP_LIKE (email, '[A-Z0-9._%~]+@[A-Z0-9._%~]+\.[A-Z]{2,4}' );
```

REGEXP_SUBSTR

A SUBSTR műveletet egészíti ki reguláris kifejezésekkel. Magával a rész-karakterlánccal tér vissza.



Regex_substr(karakterlánc, minta [, kezdő pozíció [, keresett előfordulás [, találati paraméterek]]])

■ 1. A 'call', 'caller', 'called, vagy 'calling'

```
SELECT REGEXP_SUBSTR('You have called me too often, she said.,  
, 'call((ing)|(er)|(ed))') FROM dual;
```

--Eredmény: called

■ 2. A 3-ik mezőt : elválasztóval

```
SELECT REGEXP_SUBSTR('system/pwd@orabase:1521:sidval', '[^:]+', 1, 3)  
FROM DUAL; --Eredmény: Sidval
```

■ 3. Az első szám

```
SELECT REGEXP_SUBSTR ('2, 5, and 10 are numbers in this example', '\d')  
FROM dual; --Eredmény: 2
```

■ 4. Az első kétjegyű szám

```
SELECT REGEXP_SUBSTR ('2, 5, and 10 are numbers in this example', '(\d)(\d)')  
FROM dual; --Eredmény: 10.
```

■ 5. Második magánhangzó előfordulás

```
SELECT REGEXP_SUBSTR ('TechOnTheNet', 'a|e|i|o|u', 1, 2, 'i') FROM dual;  
-- Eredmény: 'O'
```


-
- 1. Megkeresi a 6-ik előfordulását egy non blank karaktereknek (válasz 37)
 - `SELECT REGEXP_INSTR('500 Oracle Parkway, Redwood Shores, CA', '[^]+', 1, 6) FROM DUAL;`
 - 2. Megkeresi az első karakter pozícióját a címben
 - `SELECT REGEXP_INSTR(street_address,'[[:alpha:]]') FROM locations;`
 - 3. s,r,p-vel kezdődő 7 hosszú szavak 3 pozíciótól kezdve, 2 előfordulás utáni
 - `SELECT REGEXP_INSTR('500 Oracle Parkway, Redwood Shores, CA', [s|r|p][[:alpha:]]{6}', 3, 2, 1, 'i') "REGEXP_INSTR" FROM DUAL;`
 - `--Eredmény: 28`
 - 4. az **ow** első előfordulása a 16-ik pozíciótól kezdve
 - `SELECT REGEXP_INSTR ('The example shows how to use the REGEXP_INSTR function', 'ow', 16, 1, 0, 'i') FROM dual;`
 - 5. Valós email cím
 - `SELECT REGEXP_INSTR(,valami sdsds@cx sds@sdf.ro', '\w+@\w+(\.\w+)+') FROM DUAL;`
-

```

SELECT
  REGEXP_INSTR
① ('0123456789',      -- source char or search value
② '(123)(4(56)(78))', -- regular expression patterns
③ 1,                 -- position to start searching
④ 1,                 -- occurrence
⑤ 0,                 -- return option
⑥ 'i',               -- match option (case insensitive)
⑦ 1)                 -- sub-expression on which to search
  "Position"
FROM dual;

```

Position	
1	2


- You may need to find a specific subpattern that identifies a protein needed for immunity in the mouse DNA.

```
SELECT
  REGEXP_INSTR('ccacctttccctccactcctcacgttctcacctgtaaagcgtccctc
cctcatccccatgcccccttaccctgcagggtagagtaggctagaaaccagagagctccaa
gctccatctgtggagaggtgccatccttgggctgcagagagaggagaaattgccccaaagc
tgctgcagagcttcaccacccttagtctcacaagccttgagttcatagcatttcttgag
tttcaccctgcccagcaggacactgcagcacccaaagggttccaggagtaggggtgcc
ctcaagaggctcttgggtctgatggccacatcctggaattggtttcaagttgatggtcaca
gcctgaggcatgtagggcgctggggatgcgctctgctctctctctctgaaccct
gaaccctctggctaccccagagcacttagagccag',
  '(gtc(tcac)(aaag))', 1, 1, 0, 'i', 1) "Position"
FROM dual;
```

```
Position
-----
195
1 rows selected
```

REGEXP_REPLACE

- Egy string-ben kereshetünk reguláris mintát és cserélhetjük ki, amire szeretnénk. A függvény minden behelyettesített karakterláncot visszaad.



- `Regexp_replace(karakterlánc, minta [, helyettesítő szöveg [, induló pozíció [, keresett előfordulás [, találati paraméterek]]])`

■ 1. A . ot – á alakítja

```
SELECT REGEXP_REPLACE(phone_number, '\.', '-') AS phone FROM emp;
```

■ 2. Keresi a xxx.xxx.xxxx és átalakítja (xxx) xxx-xxxx

```
SELECT REGEXP_REPLACE(testcol, '([[:digit:]]{3})\.[[:digit:]]{3}\.[[:digit:]]{4}',  
'(\1) \2-\3') FROM test;
```

■ 3. Betsz egy szünetet ha kisbetűt nagy követi

```
SELECT REGEXP_REPLACE('felhívott KisPista', '([[:lower:]])([[:upper:]])', '\1 \2')  
FROM DUAL;
```

■ **Eredmény:** 'felhívott Kis Pista'

■ 4. A kétjegyű számok helyett

```
SELECT REGEXP_REPLACE ('2, 5, and 10 are numbers in this example', '(\d)(\d)', '#')  
FROM dual;
```

Eredmény: '2, 5, and # are numbers in this example'

REGEXP_COUNT

- A mintának megfelelő előfordulások számát adja vissza
- `REGEXP_COUNT(karakterlánc, minta [, induló pozíció [, találati paraméterek]])`
- 1. Az a,c vagy f, karakterek száma
`select REGEXP_COUNT(name, '[acf]') from emp`
- 2. Hány t van
`SELECT REGEXP_COUNT (last_name, 't', 1, 'i') AS total FROM emp;`
- 3. Hány szóból áll
`select REGEXP_COUNT(szöveg, '[^]+') from texts;`

REGEXP_COUNT

```
SELECT REGEXP_COUNT (
  'ccacctttccctccactcctcacgttctcacctgtaaaggtccctccctcatc
  cccatgcccccttaccctgcagggtagagtaggctagaaa ccagagagctccaag
  ctccatctgtggagaggtgccatccttgggctgcagagagaggagaatttgcccc
  aaagctgcctgcagagcttcaccaaccttagtccacaaagccttgagttcatag
  ctttcttgagttttcacctgcccagcaggacactgcagcacccaaagggcttc
  ccaggagtagggttgccctcaagaggctcttgggtgatggccacatcctggaa
  ttgtttcaagttgatgtcacagccctgaggcctgtaggggctgggggatgctc
  tctgctctgctctcctctcctgaacccctgaacccctctggctacccagagcact
  tagagccag', 'gtc' ) AS Count
FROM dual;
```

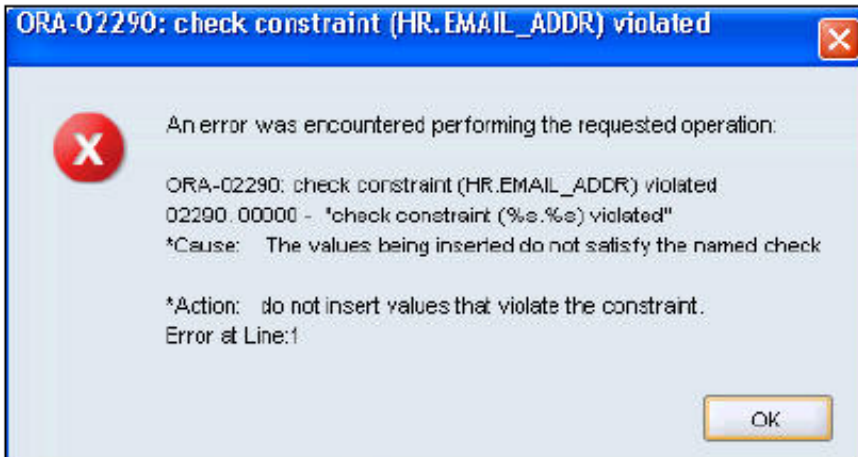


```
COUNT
-----
4
1 rows selected
```

Regular Expressions and Check Constraints: Examples

```
ALTER TABLE emp8  
ADD CONSTRAINT email_addr  
CHECK (REGEXP_LIKE(email, '@')) NOVALIDATE;
```

```
INSERT INTO emp8 VALUES  
(500, 'Christian', 'Patel', 'ChrisP2creme.com',  
1234567890, '12-Jan-2004', 'HR_REP', 2000, null, 102, 40);
```



Emlékeztető - Constraints

1. **ENABLE** ensures that all incoming data conforms to the constraint
 2. **DISABLE** allows incoming data, regardless of whether it conforms to the constraint
 3. **VALIDATE** ensures that existing data conforms to the constraint
 4. **NOVALIDATE** means that some existing data may not conform to the constraint
-

- Online gyakorlási lehetőségek!!!

- [regexr.com](https://www.regexr.com)

- https://docs.oracle.com/cd/B19306_01/appdev.102/b14251/adfns_re_gexp.htm
