CookBook ?? ?????????? ?????????? (REGEX)

Проверка работы регулярок (выставить флаги gm):

- https://regexr.com/
- https://regex101.com/

Доп чтиво:

- https://habr.com/ru/articles/545150/
- https://regex.sorokin.engineer/ru/latest/regular_expressions.html

> В KUMA все группы которые участвуют в маппинге (нормализации) должны быть именованы, пример именования "priority" для группы: `(?P<priority>\d|\d{2}|1[1-8]\d|19[01])`

> Если группа не нужна в маппинге, то можно использовать не именованную группу, пример: `(?:\d|\d{2}|1[1-8]\d|19[01])`

Простейшие приемы, практику отработаем на тестовом сообщении:

```
Message from 127.0.0.1 (localhost): KUMA is the best SIEM in 2023!
```

????????? ?????? KUMA

`KUMA` *Ищется полное соответствие строке KUMA.*

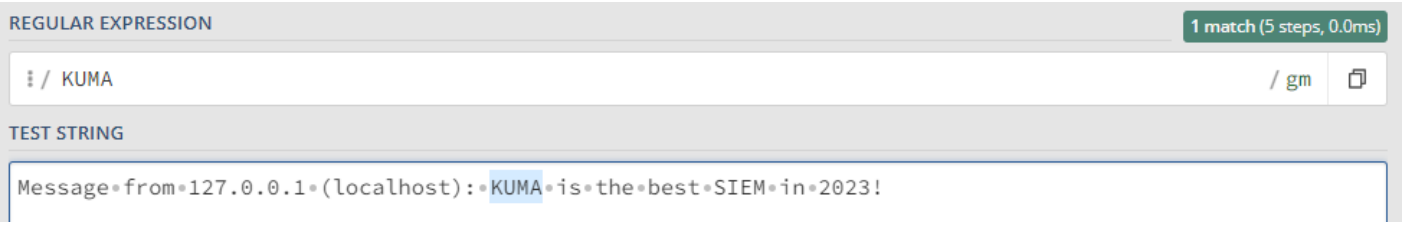

????????? ?????? ?????????? ?????? ?????

`[A-Za-z]+` *Ищем группу (**[]**) символов с большими (**A-Z**) и маленькими (**a-z**) буквами от одной и более (**+**).*

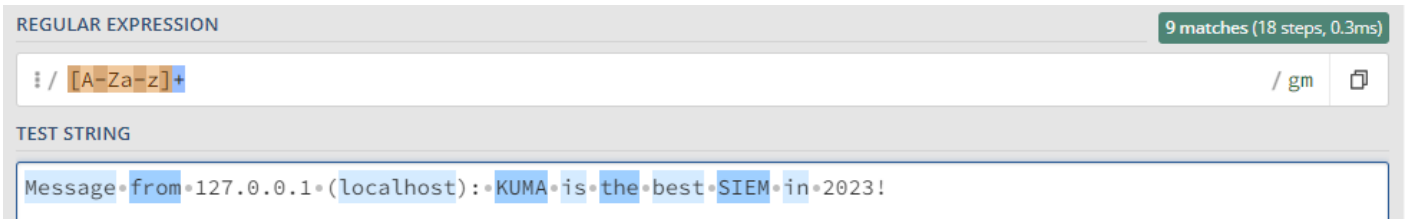

????????? ?????? ?????????? ?????? ?????

`\d+` *Ищем по токену **\d**, что является эквивалентом **[0-9]** от одного и более вхождений (**+**).*

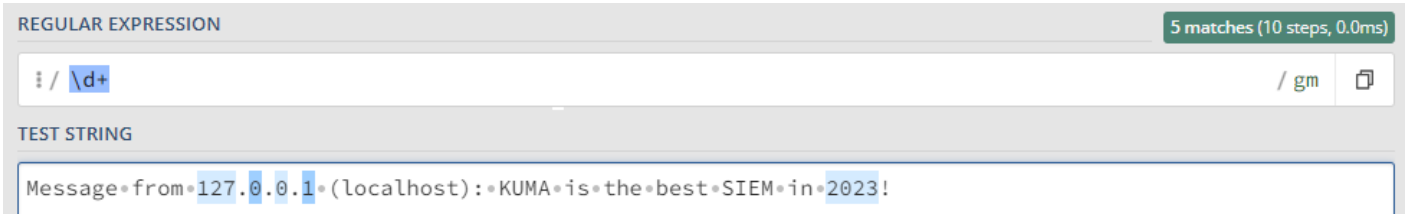

????????? ?????? ?????? ??????? ??????

`\((\w+)\)` *Ищем по токену **\w**, что является эквивалентом **[a-zA-Z0-9_]** от одного и более вхождений (**+**), при этом экранируем круглые скобки с помощью обратного слеша **** и строку нашу определяем в группу круглыми скобками **()***

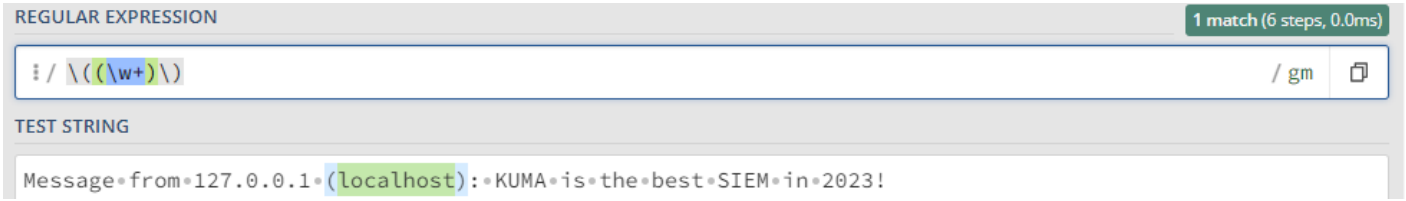

????????? ?????? ?? ?????????

`^[^\:]+` *Ищем с начала строки **^**, далее захватываем в группе все кроме двоеточия (символ двоеточия экранирован) **[^\:]** от одного и более вхождений (**+**)*

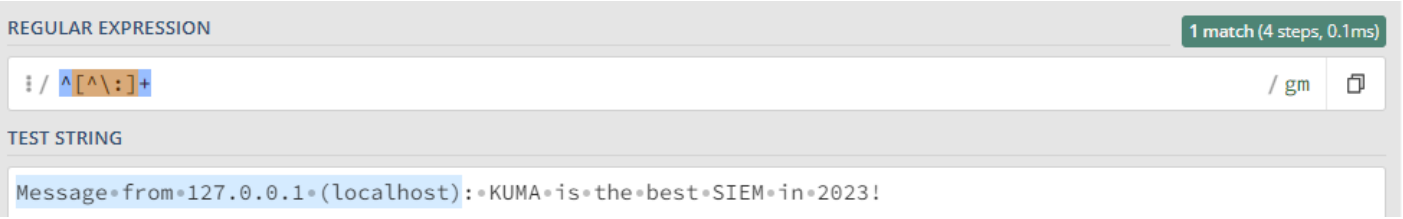

????????? ?????? ????? ?????????

`[^\:]+$` Такая, подобная предствленной выше, конструкция не подойдет, т.к. она будет очень емокой (633 шага). *Ищем все кроме двоеточия (символ двоеточия экранирован)* ***[^\:]*** *от одного и более вхождений (**+**), но до конца строки* ***$***

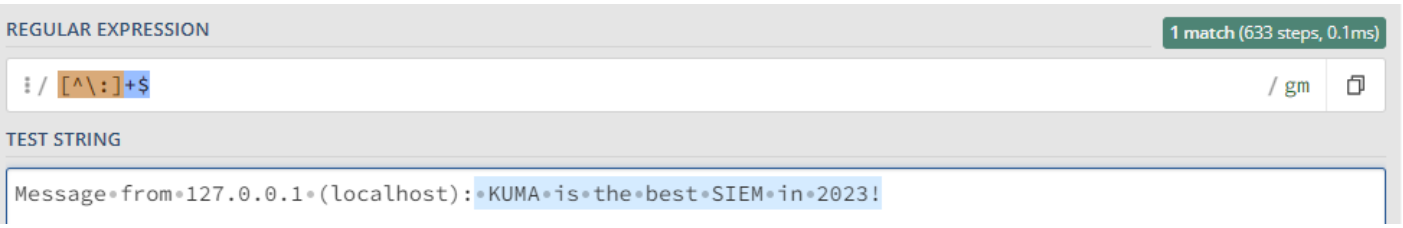

В нашем случае лучше использовать следующее

`\:(.*)$` *Ищем в строке двоеточие* ***\:****, далее захватываем все символы от нуля и более вхождений (*), и берем все что нам нужно в группу* ***()***

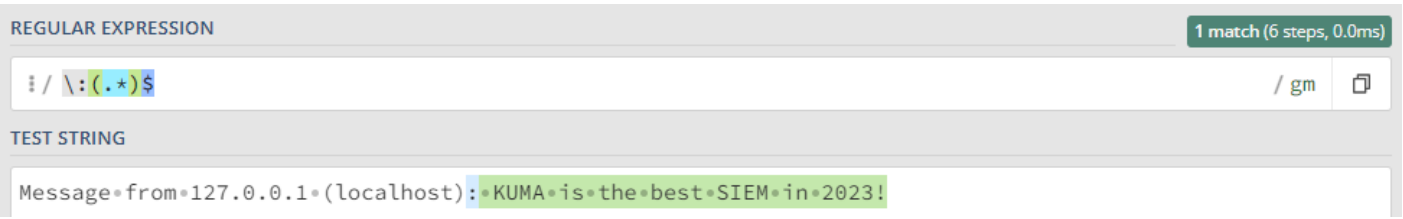

????????? IP-?????

`\d+\.\d+\.\d+\.\d+` *Ищем числа от одного и более* ***\d+****, с точкой и так 4 раза*

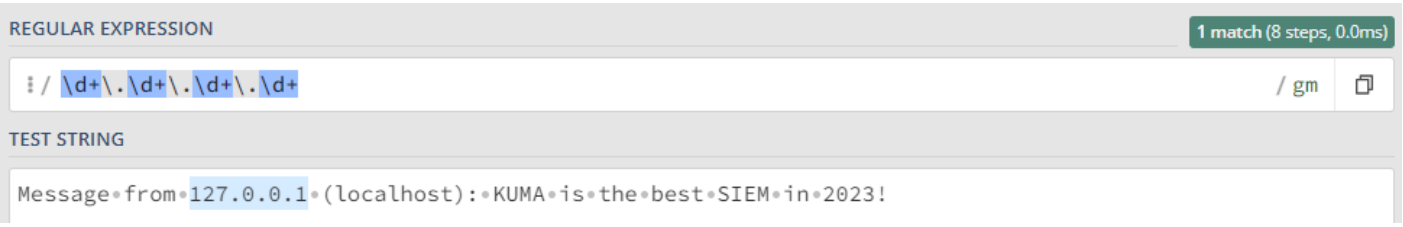

????????? ????? ????????? ?? 4 ????

`\b[a-zA-Z]{4}\b` *Ищем группу 4 символов из букв и разграничиваем их (boundary)* ***\b***

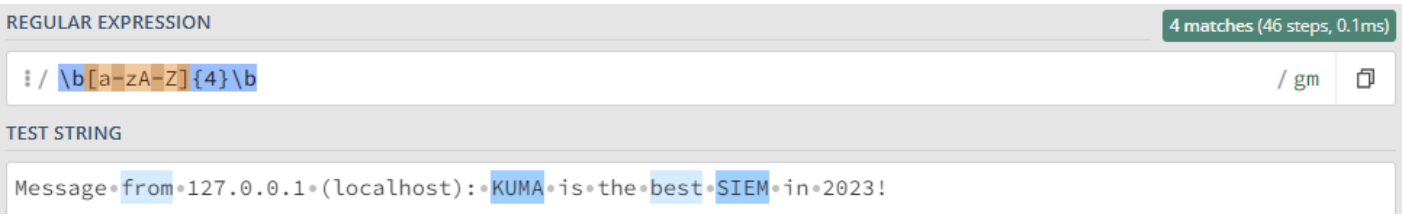

????????? ????? ????????? ?? 3 ?? 4 ????

`\b[a-zA-Z]{3,4}\b` *Ищем группу 4 символов из букв и разграничиваем их (boundary)* ***\b***

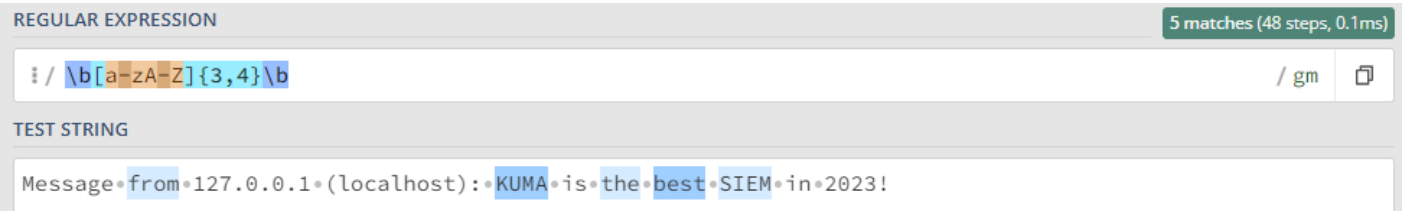

????????? IPv4 ?????

`\b((2([0-4][0-9]|5[0-5])|[0-1]?[0-9]?[0-9])\.){3}((2([0-4][0-9]|5[0-5])|[0-1]?[0-9]?[0-9]))\b`

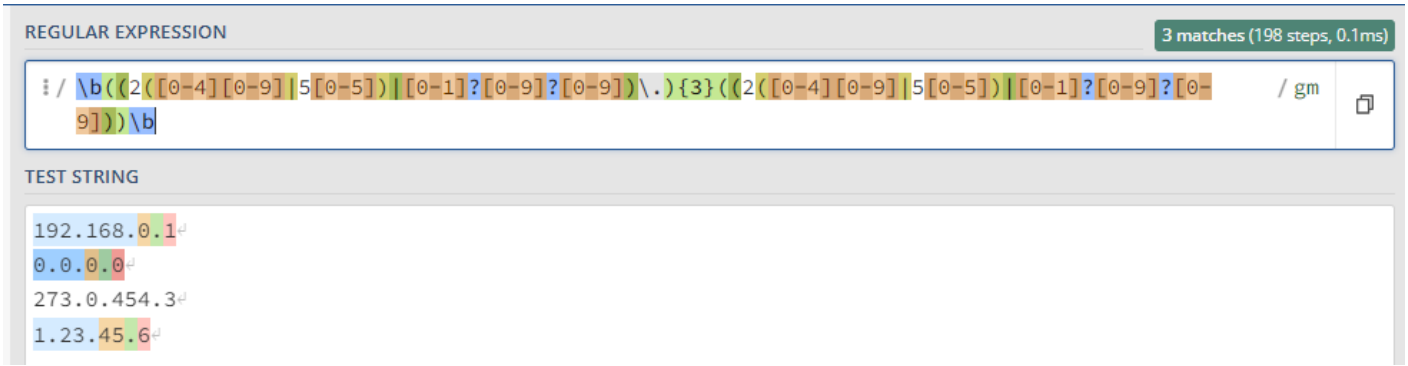

Более ленивый вариант, но быстрый, без валидации:

`(\d{1,3}\.\d{1,3}\.\d{1,3}\.\d{1,3})`

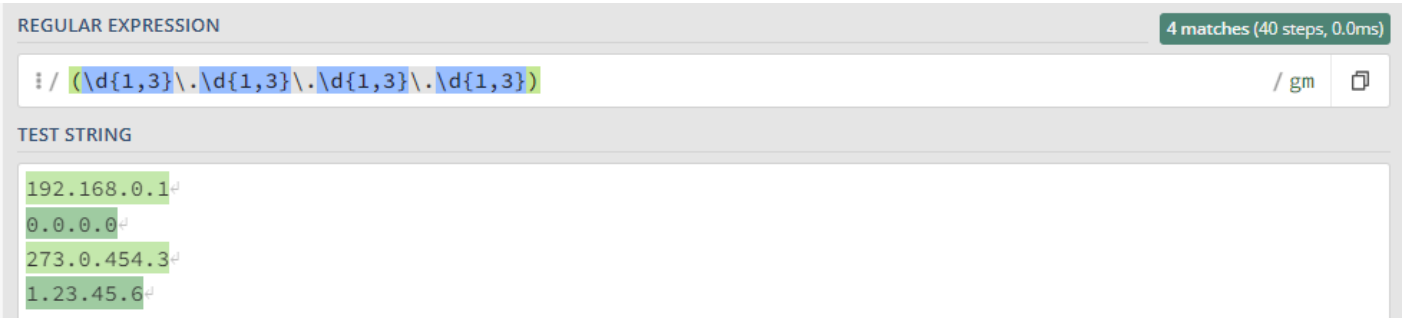

????????? IPv6 ?????

`(([a-fA-F0-9]{1,4}|):){1,7}([a-fA-F0-9]{1,4}|:)`

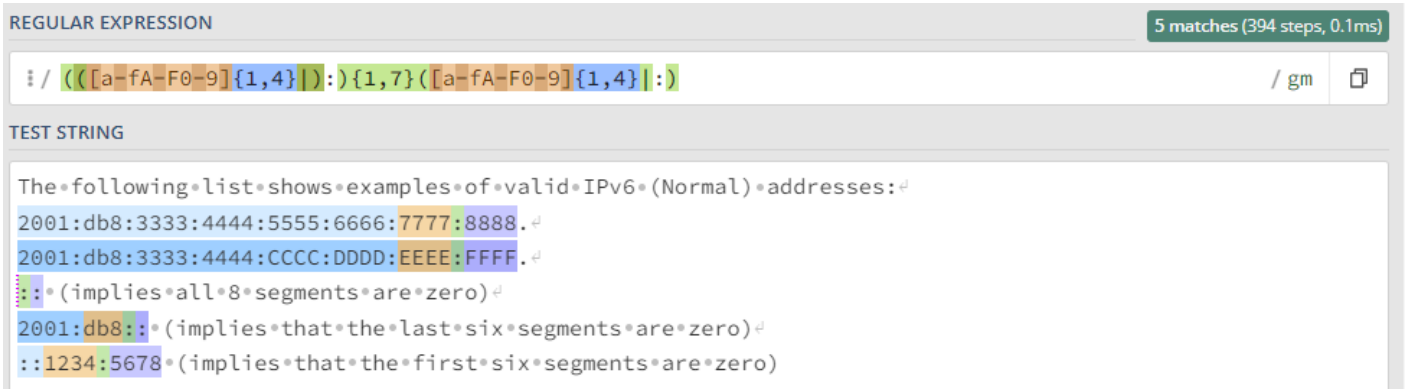

????????? HASH ?????

- MD `^[a-fA-F0-9]{32}$`
- SHA1 `^[a-fA-F0-9]{40}$`
- SHA256 `^[a-fA-F0-9]{64}$`
- SHA512 `^[a-fA-F0-9]{128}$`

????????? URL ?????

`^((https?:\/\/)?([\da-z\.-]+\.[a-z\.]{2,6}|[\d\.]+)([\/:?=&#]{1}[\da-z\.-]+)*\S+)$`

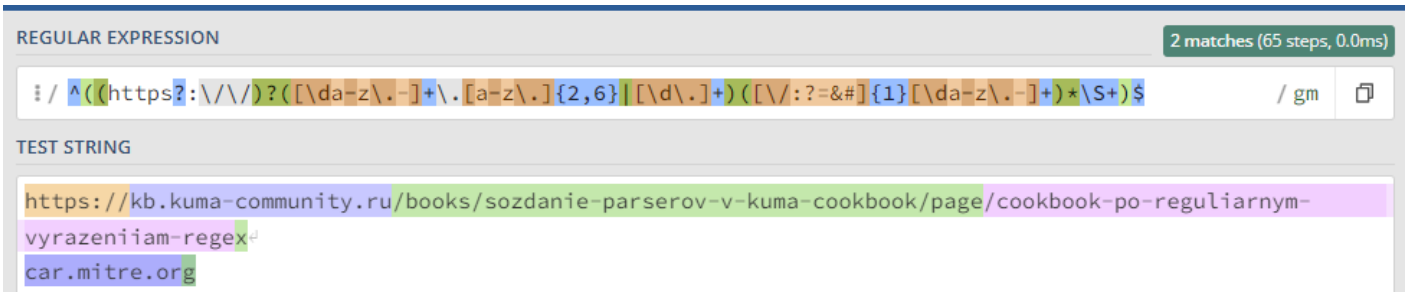

????????? EMAIL ?????

Определяет почти все типы валидных адресов

```
\b[\w\.\-\+\!\/\"\%]+@[\w\.-]+(\.\w{2,4})?\b
```

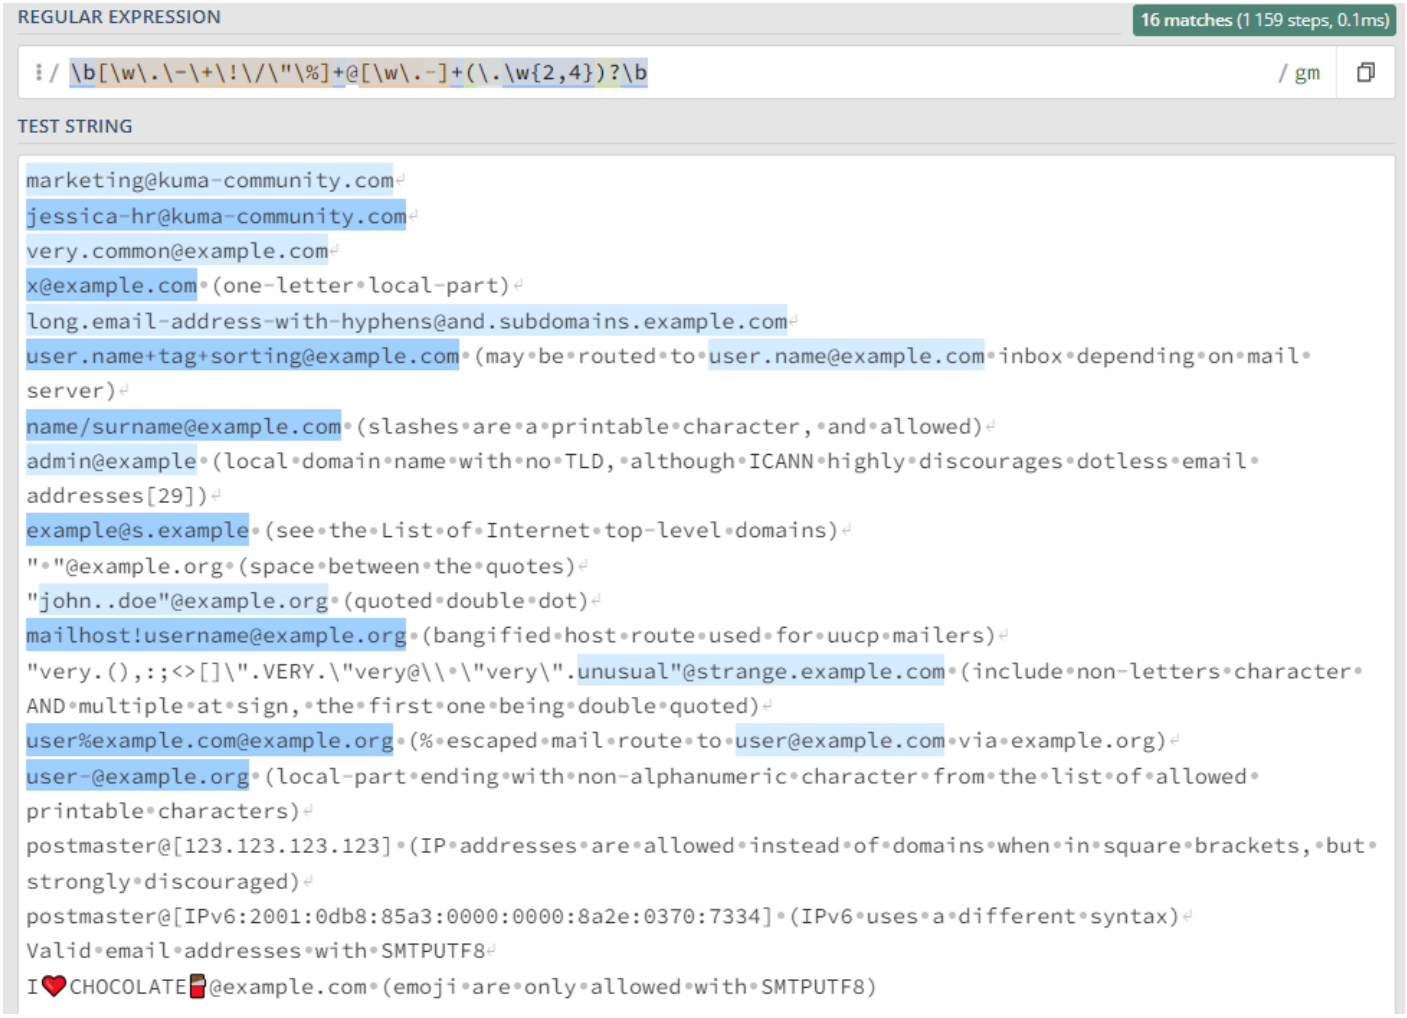

????????? CSV ?????????

Создаются группы по значениям из CSV

```
(?:\s*(?:\"([^\"]*)\"|([^,]+))\s*,?)+?
```

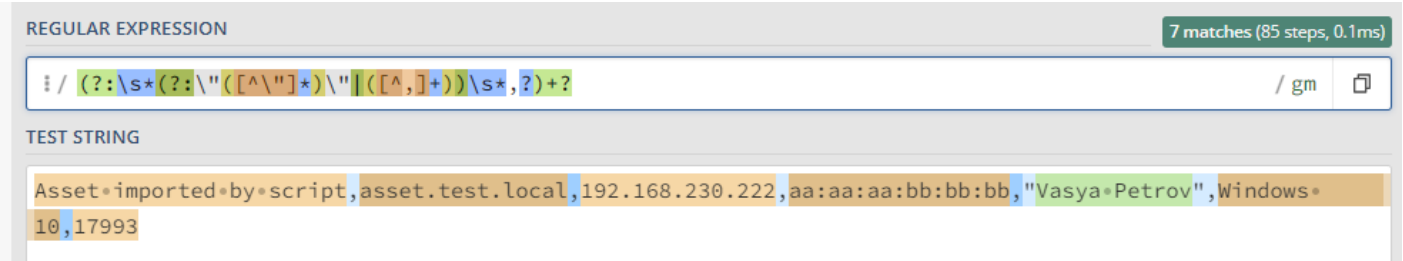

????????? Syslog ?????????

Разбираются сообщения по rfc https://datatracker.ietf.org/doc/html/rfc5424 и

https://datatracker.ietf.org/doc/html/rfc3164

```
(?P<syslog>^<(?P<priority>\d|\d{2}|1[1-8]\d|19[01])>(?P<version>\d{1,2})?\s?(?P<timestamp>(?P<rfc3164>[A-Z][a-z][a-z]\s{1,2}\d{1,2}\s\d{2}[:]\d{2}[:]\d{2})|(?P<rfc5424>\d{4}[-]\d{2}[-]\d{2}[T]\d{2}[:]\d{2}[:]\d{2}(?:\.\d{1,6})?(?:[+-]\d{2}[:]\d{2}|Z)?))\s?(?P<hostname>[\S]{1,255})\s?(?P<appname>[\/\w-]{1,48})?\s?\[?(?P<procid>[\w]{1,128})?(?P<delimMSG>\]\:\s|\s\-\s|\:\s|\s)(?P<BIGmsg>(?P<msgid>[\S]{1,32})?(?P<delimMSGID>\]\:\s|\s\-\s|\:\s|\s)?(?P<structureddata>\[.+[\]]+|-)?(?:\s(?P<msg>.+))?)$)
```

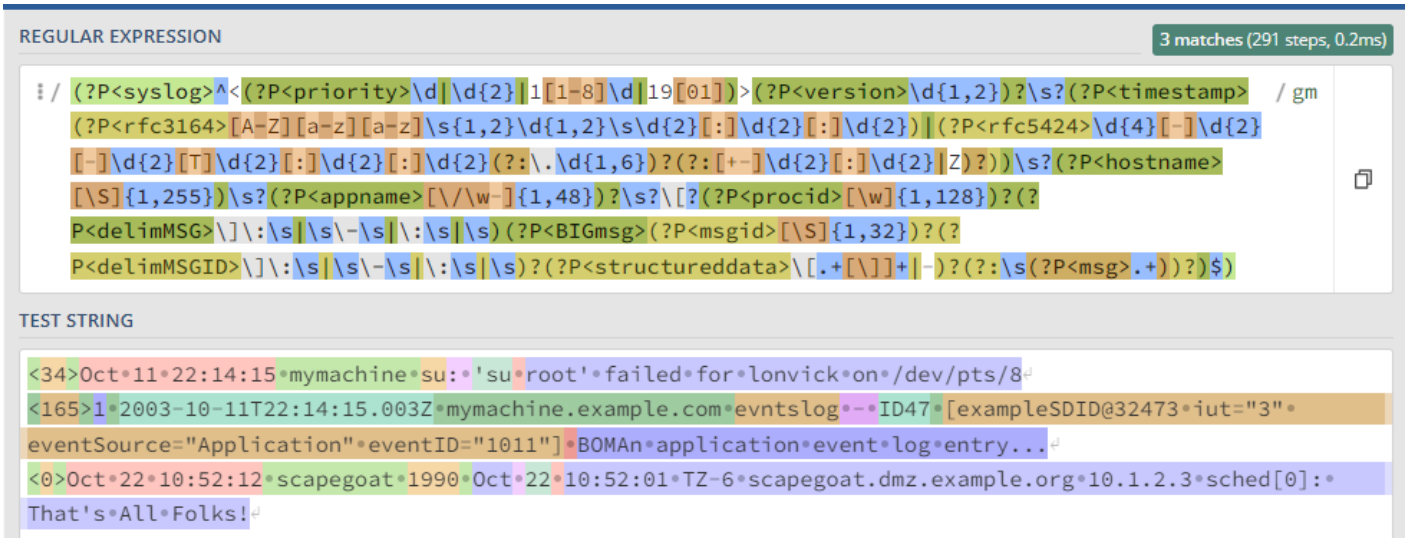

????????? ??????? (?? ????? ? ?? ?????)

```
[^\w \xC0-\xFF]
```

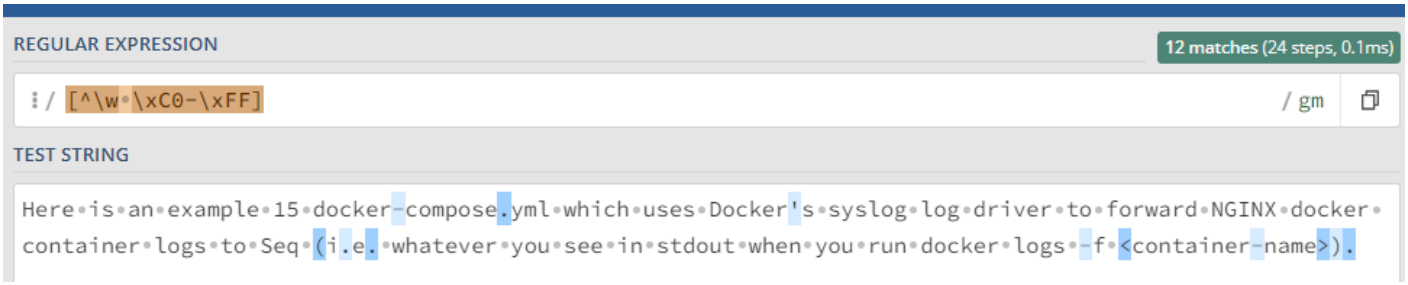

?????? ? ????????????? ??????????

В regexp существуют следующие флаги:

- `i` - нечувствителен к регистру (по умолчанию false)
- `m` - многострочный режим, ^ и $ соответствуют строке начала/конца в дополнение к тексту начала/конца (по умолчанию false)
- `s` - позволяет `.` (точке) совпадать с `\n` (по умолчанию false)
- `U` - не жадный режим, меняет местами значения x* и x*?, x+ и x+? и т. д. (по умолчанию false)

Синтаксис флага: xyz (установить) или -xyz (очистить) или xy-z (установить xy, очистить z).

Устанавливаем флаг s

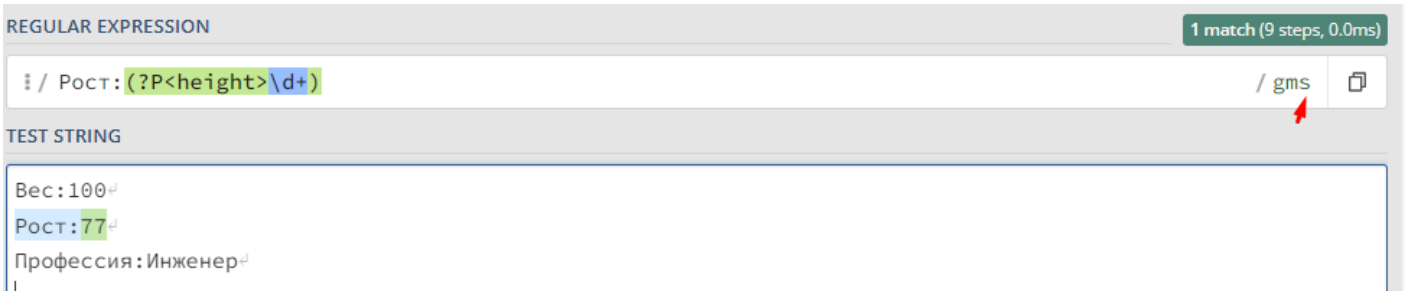

Использование в KUMA:

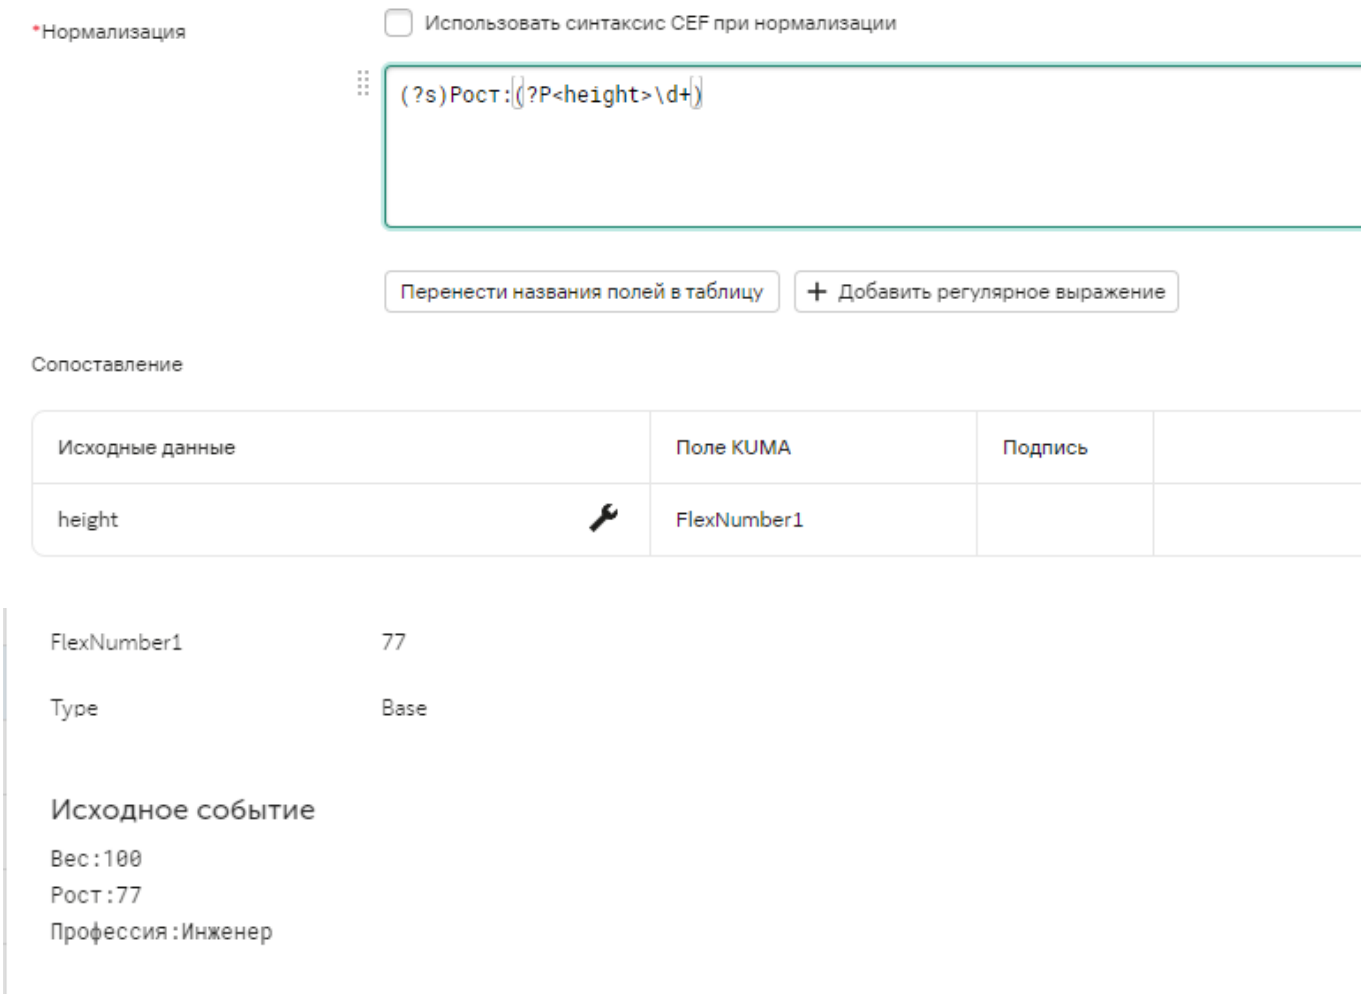

?????? ??????????? ? ????????? KV

Иногда в структуре KV разделитель пробел создает нам проблемы, пример такого события:

```
pid=\"29753\" appname=\"DBeaver 23.2.1 - SQLEditor <Script-40.sql>\" user=\"user2\" dbname=\"test_db\" rhost=\"comp.local(911)\" queryid=\"0\" command_tag=\"BIND\" sql_state=\"42501\" session_id=\"6662a086.7439\" session_seq=\"74\" session_start_time=\"2024-06-07 05:54:14 UTC\" virt_trans_id=\"5/231\" trans_id=\"0\" msg=STATEMENT: select lo_export(111,'/tmp/pido')
```

В примере значение по ключу msg без кавычек, и оно будет некорректно парситься, поэтому можно, либо заменами добавить эти кавычки, либо воспользоваться приемом полегче и сделать разделитель, например |

Для этого используем функцию replaceWithRegexp:

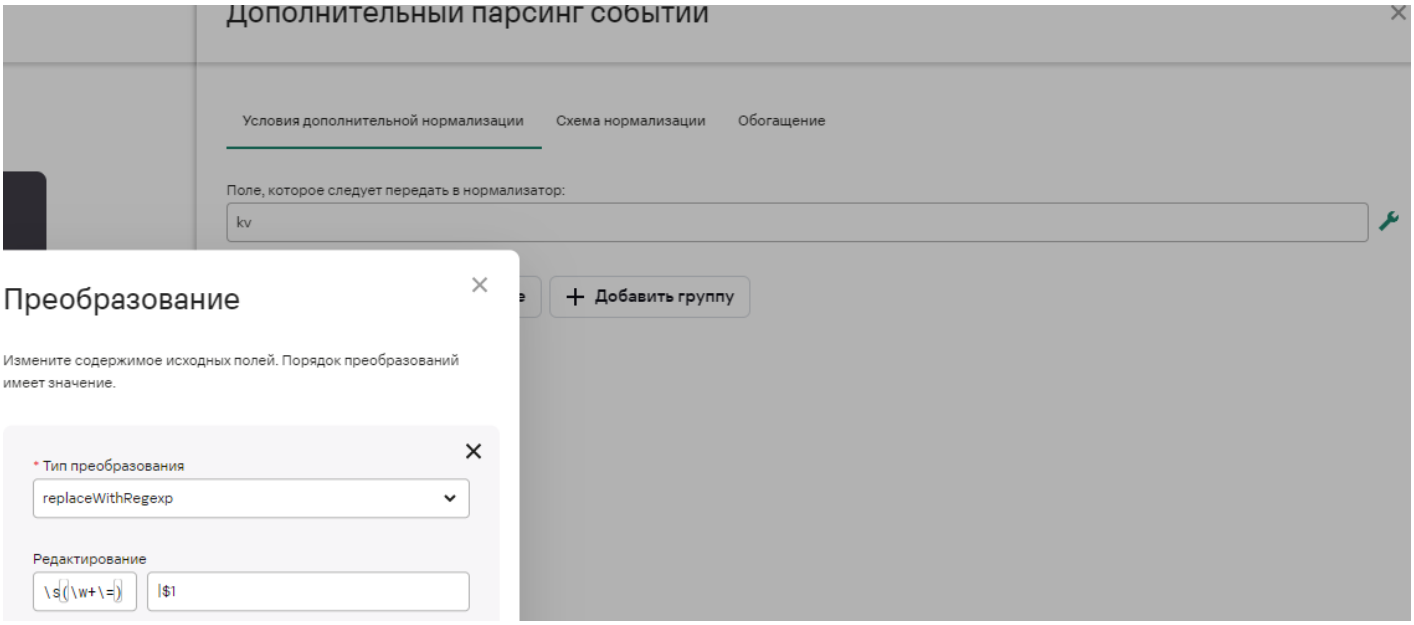

Вот как выглядит будет замена:

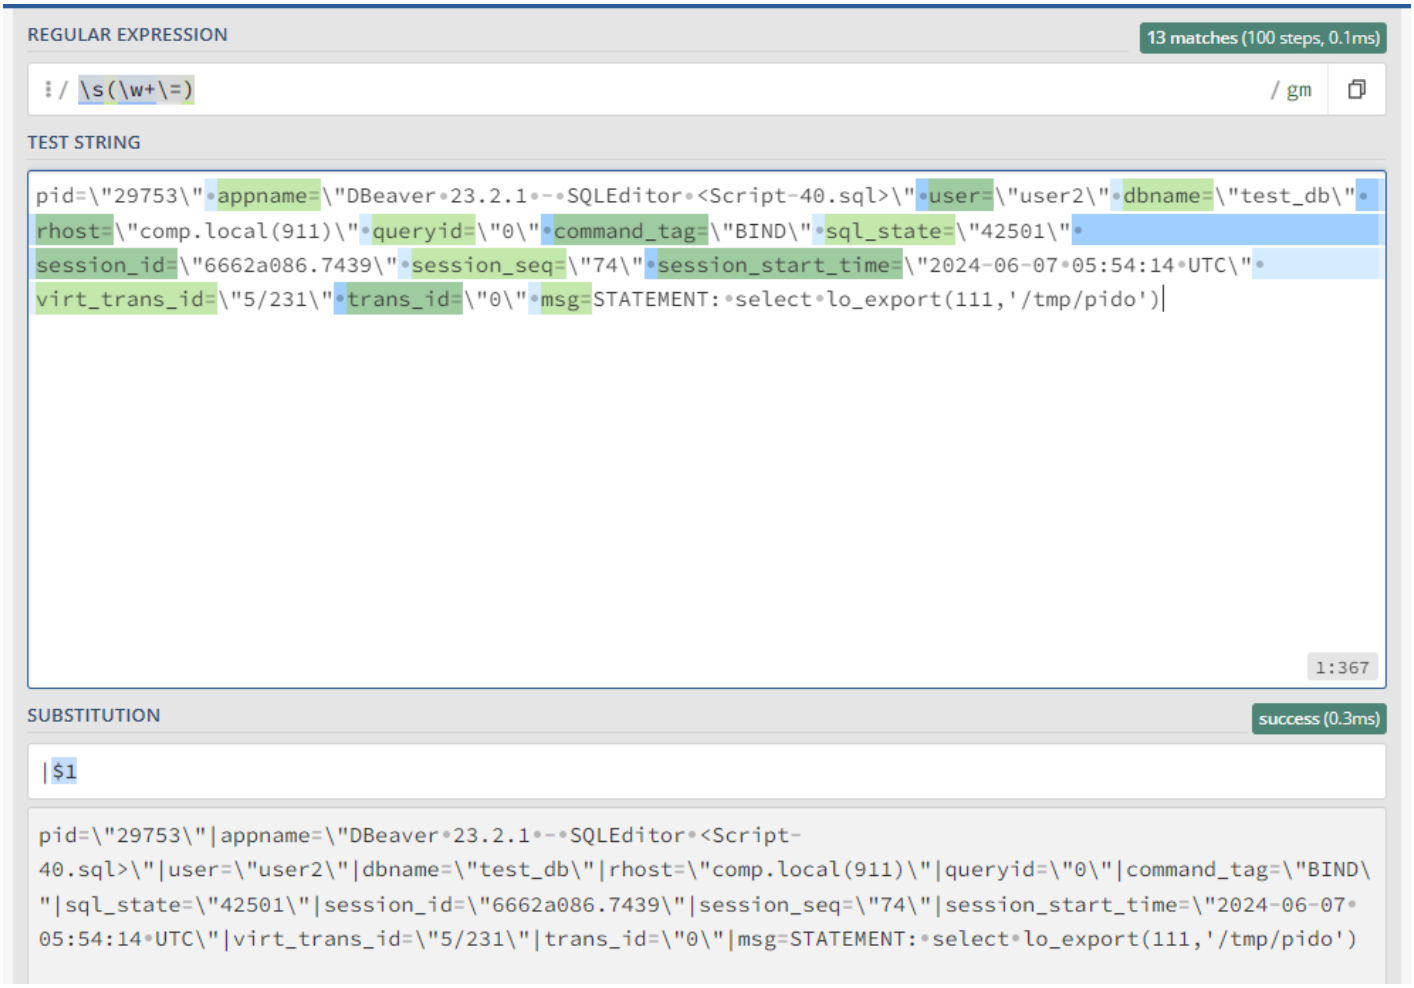

Вот как это выглядит в KUMA:

Service	TEST BORIS (TCP/5577)
Type	Base
Extra	appname: \"DBeaver 23.2.1 - SQLEditor <Script-40.sql>\" command_tag: \"BIND\" dbname: \"test_db\" delim: • kv: pid=\"29753\"•appname=\"DBeaver 23.2.1 - SQLEditor <Script-40.sql>\"•user=\"user2\"•dbname=\"test_db\"•rhost=\"comp.local(911)\"•queryid=\"0\"•command_tag=\"BIND\"•sql_state=\"42501\"•session_id=\"6662a086.7439\"•session_seq=\"74\"•session_start_time=\"2024-06-07 05:54:14 UTC\"•virt_trans_id=\"5/231\"•trans_id=\"0\"•msg=STATEMENT: select lo_export(111,/tmp/pido) ms: .685 msg: STATEMENT: select lo_export(111,/tmp/pido) pid: \"29753\" queryid: \"0\" rfc5424_modif: 2024-06-07 05:54:14.685 rhost: \"comp.local(911)\" session_id: \"6662a086.7439\" session_seq: \"74\" session_start_time: \"2024-06-07 05:54:14 UTC\" sql_state: \"42501\" trans_id: \"0\" user: \"user2\" virt_trans_id: \"5/231\"

????? ?????????

Anchors

^	Start of string, or start of line in multi-line pattern
\A	Start of string
$	End of string, or end of line in multi-line pattern
\Z	End of string
\b	Word boundary
\B	Not word boundary
\<	Start of word
\>	End of word

Character Classes

\c	Control character
\s	White space
\S	Not white space
\d	Digit
\D	Not digit
\w	Word
\W	Not word
\x	Hexadecimal digit
\O	Octal digit

POSIX

[:upper:]	Upper case letters
[:lower:]	Lower case letters
[:alpha:]	All letters
[:alnum:]	Digits and letters
[:digit:]	Digits
[:xdigit:]	Hexadecimal digits
[:punct:]	Punctuation
[:blank:]	Space and tab
[:space:]	Blank characters
[:cntrl:]	Control characters
[:graph:]	Printed characters
[:print:]	Printed characters and spaces
[:word:]	Digits, letters and underscore

Assertions

?=	Lookahead assertion
?!	Negative lookahead
?<=	Lookbehind assertion
?!= or ?<!	Negative lookbehind
?>	Once-only Subexpression
?()	Condition [if then]
?()|	Condition [if then else]
?#	Comment

Quantifiers

*	0 or more	{3}	Exactly 3
+	1 or more	{3,}	3 or more
?	0 or 1	{3,5}	3, 4 or 5

Add a ? to a quantifier to make it ungreedy.

Escape Sequences

\	Escape following character
\Q	Begin literal sequence
\E	End literal sequence

"Escaping" is a way of treating characters which have a special meaning in regular expressions literally, rather than as special characters.

Common Metacharacters

^	[	.	$
{	*	(	\
+	)	|	?
<	>		

The escape character is usually \

Special Characters

\n	New line
\r	Carriage return
\t	Tab
\v	Vertical tab
\f	Form feed
\xxx	Octal character xxx
\xhh	Hex character hh

Groups and Ranges

.	Any character except new line (\n)
(a|b)	a or b
(...)	Group
(?:...)	Passive (non-capturing) group
[abc]	Range (a or b or c)
[^abc]	Not (a or b or c)
[a-q]	Lower case letter from a to q
[A-Q]	Upper case letter from A to Q
[0-7]	Digit from 0 to 7
\x	Group/subpattern number "x"

Ranges are inclusive.

Pattern Modifiers

g	Global match
i *	Case-insensitive
m *	Multiple lines
s *	Treat string as single line
x *	Allow comments and whitespace in pattern
e *	Evaluate replacement
U *	Ungreedy pattern

* PCRE modifier

String Replacement

$n	nth non-passive group
$2	"xyz" in /^(abc(xyz))$/
$1	"xyz" in /^(?:abc)(xyz)$/
$`	Before matched string
$'	After matched string
$+	Last matched string
$&	Entire matched string

Some regex implementations use \ instead of $.

Revision #13
Created 2023-10-03 13:16:14 UTC by Boris Rzr
Updated 2024-12-03 11:31:20 UTC by Boris Rzr