

Ricerca e sostituzione di testo

Funzioni per la ricerca e la sostituzione di testo, con i pacchetti *base* e *stringr*.

Se il campo è composto da una sola parola, la ricerca del testo (e la sua sostituzione) funziona come la ricerca di valori di altro tipo:

```
library(tidyverse)
```

```
# include gli NA, quindi il risultato è un po' diverso
starwars[starwars$gender == 'feminine',]
<code>
```

Oppure

```
<code rsplus>
starwars %>%
  filter(gender == 'feminine')
```

```
# A tibble: 17 x 14
  name height mass hair_color skin_color eye_color birth_year sex
gender
  <chr> <int> <dbl> <chr> <chr> <chr> <dbl>
<chr> <chr>
1 Leia~ 150 49 brown light brown 19
fema~ femin~
2 Beru~ 165 75 brown light blue 47
fema~ femin~
3 Mon ~ 150 NA auburn fair blue 48
fema~ femin~
4 Shmi~ 163 NA black fair brown 72
fema~ femin~
5 Ayla~ 178 55 none blue hazel 48
fema~ femin~
6 Adi ~ 184 50 none dark blue NA
fema~ femin~
7 Cordé 157 NA brown light brown NA
fema~ femin~
8 Lumi~ 170 56.2 black yellow blue 58
fema~ femin~
9 Barr~ 166 50 black yellow blue 40
fema~ femin~
10 Dormé 165 NA brown light brown NA
fema~ femin~
11 Zam ~ 168 55 blonde fair, gre~ yellow NA
```

```
fema~ femin~
12 Taun~    213  NA  none    grey    black    NA
fema~ femin~
13 Joca~    167  NA  white   fair    blue     NA
fema~ femin~
14 R4-P~    96   NA  none    silver, r~ red, blue  NA none
femin~
15 Shaa~    178  57  none    red, blue~ black    NA
fema~ femin~
16 Rey      NA   NA  brown   light    hazel     NA
fema~ femin~
17 Padm~    165  45  brown   light    brown     46
fema~ femin~
# ... with 5 more variables: homeworld <chr>, species <chr>, films
<list>,
#   vehicles <list>, starships <list>
```

Per la sostituzione, vedi [Ricodifica: modificare i valori](#)

Quando però la stringa è composta da più parole:

```
starwars %>%
  filter(skin_color == 'blue')
```

```
# A tibble: 2 x 14
  name height mass hair_color skin_color eye_color birth_year sex
gender
  <chr>  <int> <dbl> <chr>      <chr>      <chr>      <dbl> <chr>
<chr>
1 Ayla~   178    55 none       blue       hazel         48 fema~
femin~
2 Mas ~   196    NA none       blue       blue          NA male
mascu~
# ... with 5 more variables: homeworld <chr>, species <chr>, films
<list>,
#   vehicles <list>, starships <list>
```

I campi che contengono la parola “blue” insieme ad altre, non vengono individuati.

In questi casi, o per ricerche più complesse, si devono usare le funzioni per la ricerca di testo *all'interno delle stringhe*, presenti nella distribuzione base di R, e nei pacchetti *stringi* e *stringr*. Le funzioni di base vengono caricate all'avvio di R, quelle di *stringr* fanno parte dei pacchetti caricati con `library(tidyverse)`

Il pattern di ricerca

In tutte queste funzioni, il *pattern* di ricerca viene interpretato come *espressione regolare* (*regex*, o *regexp*): potrà trattarsi dunque di una stringa semplice, di una classe o set, come anche di una espressione più complessa.

Le espressioni regolari devono essere inserite fra virgolette (sono stringhe di testo):

```
# una parola
starwars$skin_color[grep("blue", starwars$skin_color)]
```

```
[1] "white, blue"      "blue, grey"      "blue"
[4] "blue, grey"      "white, blue"     "blue"
[7] "grey, blue"      "red, blue, white"
```

```
# OR
starwars$skin_color[grep("blue|white", starwars$skin_color)]
```

```
# nomi che cominciano per L
starwars$name[grep("^L", starwars$name)]
```

```
# nomi che contengono numeri
starwars$name[grep("[0-9]", starwars$name)]
# oppure
starwars$name[grep("[:digit:]", starwars$name)]
```

Vedi:

- Voce: [Espressioni regolari in R](#);
- [sintassi regex in R](#)

Ricerca di testo

Tab. 1: Ricerca: sintesi

	base	stringr	
ricerca	<code>grep(pattern, x)</code>	<code>str_which(x, pattern)</code>	Vettore con gli elementi corrispondenti
	<code>grepl(pattern, x)</code>	<code>str_detect(x, pattern)</code>	Vettore logico
inverso	<code>invert = FALSE</code> (solo <code>grep()</code>)	<code>negate = FALSE</code>	
Ignora maiuscole/minuscole	<code>ignore.case = TRUE</code>	<code>pattern = regex(..., ignore_case = TRUE)</code>	

grep e grepl

Queste funzioni seguono la sintassi *grep* (*general regular expression print*): il pattern di ricerca precede l'oggetto, ovvero la stringa o il vettore di stringhe in cui effettuare la ricerca:

```
grep(pattern, x)
```

La principale differenza fra queste due funzioni consiste nel tipo di risultato prodotto:

```
# indici dei casi che contengono la parola 'blue'  
grep("blue", starwars$skin_color)
```

```
[1] 3 38 44 45 46 56 72 76
```

Qui abbiamo un vettore che contiene gli indici degli elementi corrispondenti al pattern.

```
# vettore logico  
grepl("blue", starwars$skin_color)
```

```
[1] FALSE FALSE TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  
FALSE  
[12] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  
FALSE  
[23] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  
FALSE  
[34] FALSE FALSE FALSE FALSE TRUE FALSE FALSE FALSE FALSE FALSE  
TRUE  
[45] TRUE TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  
FALSE  
[56] TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  
FALSE  
[67] FALSE FALSE FALSE FALSE FALSE TRUE FALSE FALSE FALSE TRUE  
FALSE  
[78] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
```

Qui abbiamo invece un vettore logico della stessa lunghezza di quello originale, in cui TRUE = contiene la parola 'blue'.

Per selezionare le righe utilizzando gli indici, possiamo utilizzare indifferentemente l'una o l'altra funzione:

```
starwars[grep("blue", starwars$skin_color),]
```

```
starwars[grepl("blue", starwars$skin_color),]
```

Ma se vogliamo usare i risultati in una funzione che richiede di indicare una condizione (ad esempio `filter()`; vedi [la voce](r:gestione_dei_dati:dplyr_filter)), dobbiamo usare necessariamente `grepl()`, che restituisce i risultati in termini di vero/falso:

```
starwars %>%
  filter(grep('blue', skin_color))
```

Restituisce un messaggio di errore:

```
Error: Problem with 'filter()' input '...' i Input '...' is
'grep("blue", skin_color)'. x Input '...' must be of size 87 or
1, not size 8. Run 'rlang::last_error()' to see where the error
occurred.
```

```
starwars %>%
  filter(grepl('blue', skin_color))
```

```
# A tibble: 8 x 14
  name      height  mass hair_color skin_color  eye_color birth_year
sex
  <chr>      <int> <dbl> <chr>      <chr>      <chr>      <dbl>
<chr>
1 R2-D2         96   32 NA         white, blue red          33
none
2 Watto        137   NA black      blue, grey  yellow      NA
male
3 Ayla Secura  178   55 none       blue        hazel       48
fema~
4 Dud Bolt      94   45 none       blue, grey  yellow      NA
male
5 Gasgano      122   NA none       white, blue black        NA
male
6 Mas Amedeus  196   NA none       blue        blue        NA
male
7 Ratts Tyroca  79   15 none       grey, blue  unknown     NA
male
8 Shaak Ti     178   57 none       red, blue, ~ black    NA
fema~
# ... with 6 more variables: gender <chr>, homeworld <chr>, species
<chr>,
#   films <list>, vehicles <list>, starships <list>
```

Ignora maiuscolo/minuscolo

Per cercare un termine senza considerare le lettere maiuscole e minuscole, usiamo

l'argomento `ignore.case`:

```
starwars %>%  
  filter(grepl('Green', skin_color, ignore.case = TRUE))
```

```
# A tibble: 11 x 14  
  name      height  mass hair_color skin_color eye_color birth_year  
sex  
  <chr>      <int> <dbl> <chr>      <chr>      <chr>      <dbl>  
<chr>  
1 Greedo      173    74 NA          green      black          44  
male  
2 Jabba D~    175  1358 NA          green-tan,~ orange        600  
herma~  
3 Yoda         66    17 white       green      brown          896  
male  
4 Bossk       190   113 none        green      red            53  
male  
5 Nute Gu~    191    90 none        mottled gr~ red           NA  
male  
6 Rugor N~    206   NA none        green      orange         NA  
male  
7 Ben Qua~    163    65 none        grey, gree~ orange         NA  
male  
8 Kit Fis~    196    87 none        green      black           NA  
male  
9 Poggle ~    183    80 none        green      yellow          NA  
male  
10 Zam Wes~   168    55 blonde     fair, gree~ yellow          NA  
female  
11 Wat Tam~   193    48 none        green, gre~ unknown         NA  
male  
# ... with 6 more variables: gender <chr>, homeworld <chr>, species  
<chr>,  
#   films <list>, vehicles <list>, starships <list>
```

str_which e str_detect

Queste due funzioni corrispondono, rispettivamente, a `grep` e `grepl`.

```
starwars %>%  
  filter(str_detect(skin_color, 'blue'))
```

equivale quindi a

```
starwars %>%
  filter(grepl('blue', skin_color))
```

Possono essere preferibili alle funzioni di base, in quanto la sintassi degli argomenti è quella 'normale', con l'oggetto (stringa), cioè, che precede il pattern:

```
str_detect(x, pattern)
```

Inoltre, così come le altre funzioni di *stringr*, sono più efficienti e veloci nell'esecuzione.

Invertire i risultati di ricerca

Trovare i casi che non corrispondono ai risultati, con `invert = TRUE`:

```
# personaggi che non hanno la pelle blu
starwars[grepl("blue", starwars$skin_color, invert = T),]
```

```
# A tibble: 79 x 14
  name      height  mass hair_color skin_color eye_color birth_year
sex
  <chr>      <int> <dbl> <chr>      <chr>      <chr>      <dbl>
<chr>
1 Luke Sky~   172    77 blond      fair      blue      19
male
2 C-3PO      167    75 NA        gold      yellow    112
none
3 Darth Va~  202   136 none      white     yellow    41.9
male
4 Leia Org~  150    49 brown     light     brown     19
fema~
5 Owen Lars  178   120 brown, grey light     blue      52
male
6 Beru Whi~  165    75 brown     light     blue      47
fema~
7 R5-D4      97    32 NA        white, red red       NA
none
8 Biggs Da~  183    84 black     light     brown     24
male
9 Obi-Wan ~  182    77 auburn, wh~ fair      blue-gray  57
male
10 Anakin S~  188    84 blond     fair      blue      41.9
male
# ... with 69 more rows, and 6 more variables: gender <chr>,
# homeworld <chr>, species <chr>, films <list>, vehicles <list>,
```

```
# starships <list>
```

Equivale a

```
starwars[str_which(starwars$skin_color, 'blue', negate = T),]
```

dove l'argomento da usare è `negate = TRUE`.

Volendo usare `grep()` dobbiamo usare la negazione (!) e scrivere:

```
starwars[!grep("blue", starwars$skin_color),]
```

Che equivale a

```
starwars[str_detect(starwars$skin_color, 'blue', negate = T),]
```

stringr: Ignora maiuscolo/minuscolo

Nelle funzioni di *stringr* che stiamo prendendo qui in considerazione, per ignorare le maiuscole o le minuscole, dobbiamo definire il pattern usando la funzione `regex()` (vedi [l'aiuto](#)):

```
starwars %>%  
  filter(str_detect(skin_color, regex("Green", ignore_case = T)))
```

equivale cioè a:

```
starwars %>%  
  filter(grep("Green", skin_color, ignore.case = TRUE))
```

Sostituzione

Quanto detto sin qui vale anche per le funzioni che servono a sostituire le stringhe individuate attraverso la ricerca.

Tab. 2: Sostituzione: sintesi

	base	stringr	
sostituzione	<code>sub(pattern, replacement, x)</code>	<code>str_replace(x, pattern, replacement)</code>	Vettore in cui è stato sostituito solo il primo elemento corrispondente

	base	stringr	
	<code>gsub(pattern, replacement, x)</code>	<code>str_replace_all(x, pattern, replacement)</code>	Vettore in cui sono stati sostituiti tutti gli elementi corrispondenti
Ignora maiuscole/minuscole	<code>ignore.case = TRUE</code>	<code>pattern = regex(..., ignore_case = TRUE)</code>	

sub e gsub

`sub(pattern, replacement, x)`

```
frase <- "Sempre caro mi fu quest'ermo colle,
e questa siepe, che da tanta parte
dell'ultimo orizzonte il guardo esclude."
```

`sub()` sostituisce solo il primo elemento che incontra:

```
sub("quest", "QUEST", frase)
```

```
[1] "Sempre caro mi fu QUEST'ermo colle,\ne questa siepe, che da tanta
parte\ndell'ultimo orizzonte il guardo esclude."
```

`gsub()` sostituisce tutte le stringhe corrispondenti:

```
gsub("quest", "QUEST", frase)
```

```
[1] "Sempre caro mi fu QUEST'ermo colle,\ne QUESTa siepe, che da tanta
parte\ndell'ultimo orizzonte il guardo esclude."
```

Per ignorare maiuscole e minuscole:

```
gsub("Quest", "QUEST", frase, ignore.case = T)
```

```
[1] "Sempre caro mi fu QUEST'ermo colle,\ne QUESTa siepe, che da tanta
parte\ndell'ultimo orizzonte il guardo esclude."
```

str_replace

Per sostituire solo la prima occorrenza:

```
str_replace(frase, "quest", "QUEST")
```

Per sostituirle tutte:

```
str_replace_all(frase, "quest", "QUEST")
```

E, per ignorare maiuscole e minuscole, useremo la sintassi `str_replace_all(x, pattern = regex(...), replacement)`

```
str_replace_all(frase, regex("Quest", ignore_case = T), "QUEST")
```

o anche `str_replace_all(x, pattern = fixed(...), replacement)`

```
str_replace_all(frase, fixed("Questa", ignore_case = T), "QUESTA")
```

Usare elenchi di termini

le funzioni di ricerca e sostituzioni ammettono l'uso di elenchi, nella forma `c("un|alla")`.

```
str_remove_all("un albero vicino alla montagna", c("un|alla"))
```

```
## [1] " albero vicino  montagna"
```

Potremmo usare una lista di *stopword* da eliminare nel testo, in questo modo

```
lista <- paste(stopwords::stopwords("it"), collapse = "|")
```

ma gli elementi verrebbero sostituiti anche all'interno delle parole

```
str_remove_all("un albero vicino alla montagna", lista)
```

```
## [1] " br n  mntgn"
```

Per costruire la lista con le parole da interpretare come “parole intere”, facciamo precedere e seguire i termini da `\b`, che nelle espressioni regolari indica appunto il confine di una parola (`paste0("\\b", stopwords::stopwords("it"), "\\b")`).

```
# parole intere  
swc <- paste(paste0("\\b", stopwords::stopwords("it"), "\\b"),  
collapse = "|")  
swc
```

```
[1]
"\\bad\\b|\\bal\\b|\\ballo\\b|\\bai\\b|\\bagli\\b|\\ball\\b|\\bagl\\b
|\\balla\\b
|\\balle\\b|\\bcon\\b|\\bcol\\b|\\bcoi\\b|\\bda\\b|\\bdal\\b|\\bdallo
\\b|\\bdai\\b ....
```

Affinché la ricerca sia *case_insensitive*, useremo `regex(swc, ignore_case = T)`:

```
# case insensitive
str_remove_all("Un albero vicino alla montagna", regex(swc,
ignore_case = T))
```

```
## [1] " albero vicino  montagna"
```

Gli stessi risultati possono essere ottenuti con:

```
str_replace_all("Un albero vicino alla montagna", regex(swc,
ignore_case = T), "")
# oppure
gsub(swc, "", "Un albero vicino alla montagna", ignore.case = T)
```

Script di esempio

[ricerca_grep.R](#)

```
library(tidyverse)

# indici dei casi che contengono la parola 'blue'
grep("blue", starwars$skin_color)

# vettore logico
grepl("blue", starwars$skin_color)

# uso per filtrare casi
starwars[grep("blue", starwars$skin_color),]
starwars[grepl("blue", starwars$skin_color),]
starwars %>%
  filter(grepl('blue', skin_color))

# equivale a
starwars %>%
  filter(str_detect(skin_color, 'blue'))

# ignore.case
```

```
starwars %>%  
  filter(grepl('Green', skin_color, ignore.case = TRUE))  
  
# equivale a  
starwars %>%  
  filter(str_detect(skin_color, regex("Green", ignore_case = T)))
```

sostituzione_grep.R

```
frase <- "Sempre caro mi fu quest'ermo colle,  
e questa siepe, che da tanta parte  
dell'ultimo orizzonte il guardo esclude."  
  
# sub  
sub("quest", "QUEST", frase)  
# str_replace  
str_replace(frase, "quest", "QUEST")  
  
# gsub  
gsub("quest", "QUEST", frase)  
# str_replace_all  
str_replace_all(frase, "quest", "QUEST")  
  
# case insensitive  
gsub("Quest", "QUEST", frase, ignore.case = T)  
str_replace_all(frase, regex("Quest", ignore_case = T), "QUEST")  
library(tidyverse)
```

Gestione dei dati, Analisi testuale

From:
<https://www.agnesevardanega.eu/wiki/> - Ricerca Sociale con R

Permanent link:
https://www.agnesevardanega.eu/wiki/r/gestione_dei_dati/grep_ricerca_sostituzione_testo

Last update: 15/10/2025 08:28

