

Matrici testuali come grafi

Le matrici testuali possono essere analizzate ricorrendo alle misure e agli strumenti della network analysis (ampiezza, grado, centralità, densità, distanze, grappoli ecc.), in quanto una **matrice delle co-occorrenze** può essere direttamente trasformata in un grafo e rappresentata come network (**matrice di adiacenza**):

- i termini rappresentano i nodi (da, a), e
- i valori delle celle rappresenta il numero di link (o archi, o *edges*) fra i due nodi (ed eventualmente il peso).

Altre strutture di dati di uso comune nell'analisi testuale sono i dataframe dei link fra termini a due a due (**edgelist**), anch'essi direttamente interpretabili come grafi.

Testi e dati degli esempi, dove necessario anonimizzati, sono disponibili  [qui](#) (file: `es_twitter.rda`). Gli script che seguono presuppongono che testi e dati siano in una sottocartella "dati" del progetto.

Con Quanteda

La funzione `textplot_network()` di uno dei pacchetti di *Quanteda* (*quanteda.textplots*) costruisce automaticamente il network a partire da una matrice testuale (termini documenti o delle cooccorrenze):

- Vedi [Quanteda](#)

Le matrici testuali

```
# pacchetti
library(tidyverse)
library(quanteda)
quanteda_options(language_stemmer = "italian")
library(quanteda.textplots)

# dati
load("dati/es_twitter.rda")
```

Costruiamo con Quanteda una matrice delle cooccorrenze (fcm: *features cooccurrence matrix*) degli *hashtag*, a partire da un dataset di messaggi di Twitter:

```
rt.fcm <- rt2 %>%
```

```
mutate(text = str_replace_all(text, "[\\'"]", "' ')) %>%
corpus() %>%
# tokenizzazione
tokens(remove_punct = T) %>%
# matrice documenti termini
dfm() %>%
# selezione dei soli hashtags
dfm_select("#*") %>%
# soglia di occorrenze
dfm_trim(min_termfreq = 4) %>%
# matrice delle cooccorrenze
fcm()
```

Consideriamo i primi dieci termini della matrice:

```
rt.fcm[1:10,1:10]
```

Feature co-occurrence matrix of: 10 by 10 features.

	features	
features	#greenpass	#greenpassday
#greenpassrendeliberi ...		
#greenpass	4	303
52 ...		
#greenpassday	0	10
205 ...		
#greenpassrendeliberi	0	0
2 ...		
#greenpassobbligatorio	0	0
0 ...		
#portichiusi	0	0
0 ...		
#portualiditrieste	0	0
0 ...		
#lilianasegre	0	0
0 ...		
#nogreenpass	0	0
0 ...		
#libertà	0	0
0 ...		
#portualitrieste	0	0
0 ...		

I termini costituiscono sia le righe che le colonne della matrice (nello stesso ordine). I valori delle celle rappresentano le co-occorrenze, ovvero il numero delle volte in cui due termini sono compresenti nello stesso messaggio.

I termini saranno i nodi del network, mentre le cooccorrenze verranno rappresentate dalle linee che collegano i nodi.


textplot_network

Applichiamo ora la funzione `textplot_network()`, che produrrà *anche* il grafico dei termini. Due termini (o categorie, nel caso dei network semantici) che co-occorrono in uno stesso testo sono legati come due nodi di una rete. Lo spessore dei link (*edges*) fra i nodi (*vertices*) è proporzionale al valore delle celle.

```
set.seed(345)
textplot_network(rt.fcm[1:10,1:10]) +
  coord_equal()
```


Note:

- la funzione usa la sintassi di [ggplot](#)
- `set.seed()` viene inserito per ottenere sempre la stessa rappresentazione grafica, in quanto la disposizione dei nodi nello spazio è casuale;
- `coord_equal()`: quando si rappresentano i network è spesso preferibile usare un sistema di coordinate uguali (rapporto 1:1), per ridurre la distorsione (visiva) delle distanze fra i nodi



I nodi sono 9, anziché 10, perché la funzione elimina i nodi “isolati”, con frequenza inferiore a una soglia data.

```
set.seed(345)
textplot_network(rt.fcm[1:10,1:10],
                 omit_isolated = F) +
  coord_equal()
```



as.igraph

In alternativa, è possibile - con la funzione `as.igraph()` di *Quanteda* (*quanteda.textplots*) - trasformare la matrice in un grafo di *igraph*, per esportarlo in un formato standard, e lavorarci con altre librerie o software.

```
g <- as.igraph(rt.fcm[1:10,1:10],
               weighted = T)
g
```


```
IGRAPH 6832679 DNW- 9 26 --
+ attr: name (v/c), frequency (v/n), weight (e/n)
+ edges from 6832679 (vertex names):
[1] #greenpass ->#greenpassday
[2] #greenpass ->#greenpassrendeliberi
[3] #greenpassday ->#greenpassrendeliberi
[4] #greenpass ->#greenpassobbligatorio
[5] #greenpassday ->#greenpassobbligatorio
[6] #greenpassrendeliberi ->#greenpassobbligatorio
[7] #greenpassday ->#portichiusi
[8] #greenpass ->#portualiditrieste
+ ... omitted several edges
```

Che potrà essere poi stampato con `plot()`:


```
# margini
par(mar=c(0,0,0,0))

set.seed(345)
plot(g,
     asp = 1)
```

- `asp = 1` equivale a `coord_equal()` (rapporto 1:1)



- l'argomento `weighted = T` serve a far interpretare i valori nelle celle della matrice come pesi. Altrimenti, il grafo conterrebbe tanti links fra due nodi, quante sono le cooccorrenze, dando luogo ad una rappresentazione come quella che segue:



Script di esempio

text_network_quanteda.R

```
# pacchetti
library(tidyverse)
library(quanteda)
quanteda_options(language_stemmer = "italian")
library(quanteda.textplots)

# dati
load("dati/es_twitter.rda")

# matrice delle co-occorrenze
rt.fcm <- rt2 %>%
  mutate(text = str_replace_all(text, "[\\'']", "' ')) %>%
  corpus() %>%
  # tokenizzazione
  tokens(remove_punct = T) %>%
  # matrice documenti termini
  dfm() %>%
  # selezione dei soli hashtags
  dfm_select("#*") %>%
```

```
# soglia di occorrenze
dfm_trim(min_termfreq = 4) %>%
# matrice delle cooccorrenze
fcm()

# network
set.seed(345)
textplot_network(rt.fcm[1:10,1:10]) +
  coord_equal()

# grafo igraph
g <- as.igraph(rt.fcm[1:10,1:10],
               weighted = T)
```

Con igraph

Grafo non orientato

Il network precedente, diversamente dal primo, è orientato, ovvero presenta - ad esempio - una freccia che va da #portichiusi a #portualitrieste e una che va in senso inverso.

Se stiamo lavorando con le semplici cooccorrenze di termini, preferiremo con tutta probabilità un grafo non orientato (diverso sarà invece il caso dei network concettuali o semantici).

Per operare questa trasformazione (ed altre) sul grafo, possiamo usare le funzioni del pacchetto [igraph](#).


```
library(igraph)

# trasformo il grafo in un grafo non orientato
g <- g %>%
  as.undirected()
g
```

```
IGRAPH d340f6b UNW- 9 26 --
+ attr: name (v/c), frequency (v/n), weight (e/n)
+ edges from d340f6b (vertex names):
[1] #greenpass          --#greenpassday
[2] #greenpass          --#greenpassrendeliberi
[3] #greenpassday       --#greenpassrendeliberi
[4] #greenpass          --#greenpassobbligatorio
```

```
[5] #greenpassday      --#greenpassobbligatorio
[6] #greenpassrendeliberi --#greenpassobbligatorio
[7] #greenpassday      --#portichiusi
[8] #greenpass         --#portualiditrieste
+ ... omitted several edges
```

```
par(mar=c(0,0,0,0))
set.seed(345)
plot(g,
      asp = 1)
```



Attributi dei nodi e dei link

Il grafo contiene 9 nodi, 26 link, ed una serie di attributi relativi ai nodi e ai link, ereditati dalla matrice di partenza, così come il nome (che in `plot()` viene interpretato come etichetta dei nodi). Gli attributi dei nodi sono accessibili mediante le funzioni `V(g)` (per i nodi) e `E(g)` (per i link).

```
V(g)$name
```

```
[1] "#greenpass"          "#greenpassday"
"#greenpassrendeliberi"
[4] "#greenpassobbligatorio" "#portichiusi"
"#portualiditrieste"
[7] "#lilianasegre"       "#nogreenpass"
"#portualitrieste"
```

o le frequenze dei termini:

```
# frequenze dei termini
V(g)$frequency
```

```
[1] 302 1678 205 301 31 275 51 187 126
```

```
# pesi (co-occorrenze)
E(g)$weight
```

```
[1] 303 52 205 82 303 58 31 47 278 43 64 19 16 51 41 187
26 31
[19] 39 16 28 126 16 37 21 24
```

La possibilità di aggiungere e modificare le proprietà di nodi e link è di fondamentale importanza per l'analisi di queste reti.

Da una matrice di adiacenza (cooccorrenze)

Un grafo può essere costruito dalla matrice delle cooccorrenze anche con la funzione `graph_from_adjacency_matrix()` di *igraph*¹⁾. Torniamo all'esempio precedente:

```
graph_from_adjacency_matrix(rt.fcm[1:10,1:10])
```

```
IGRAPH b9aaf63 DN-- 10 2248 --
+ attr: name (v/c)
+ edges from b9aaf63 (vertex names):
[1] #greenpass->#greenpass #greenpass->#greenpass
[3] #greenpass->#greenpass #greenpass->#greenpass
[5] #greenpass->#greenpassday #greenpass->#greenpassday
[7] #greenpass->#greenpassday #greenpass->#greenpassday
[9] #greenpass->#greenpassday #greenpass->#greenpassday
[11] #greenpass->#greenpassday #greenpass->#greenpassday
[13] #greenpass->#greenpassday #greenpass->#greenpassday
[15] #greenpass->#greenpassday #greenpass->#greenpassday
+ ... omitted several edges
```

Volendo un grafo non orientato, ponderato e semplificato:

```
g2 <- graph_from_adjacency_matrix(rt.fcm[1:10,1:10],
                                   # pesi
                                   weighted = T) %>%
  # non orientato
  as.undirected() %>%
```

```
# semplificato
simplify()
g2
```


```
IGRAPH 0776c35 UNW- 10 42 --
+ attr: name (v/c), weight (e/n)
+ edges from 0776c35 (vertex names):
[1] #greenpass --#greenpassday
[2] #greenpass --#greenpassrendeliberi
[3] #greenpass --#greenpassobbligatorio
[4] #greenpass --#portichiusi
[5] #greenpass --#portualiditrieste
[6] #greenpass --#lilianasegre
[7] #greenpass --#nogreenpass
[8] #greenpass --#libertà
+ ... omitted several edges
```

Possiamo recuperare le informazioni sulle frequenze dei termini dai metadati della matrice, ed aggiungerle come attributo dei nodi:

```
V(g2)$frequency <- meta(rt.fcm, "margin", "object")[1:10]
```

Nel grafico che segue, vediamo un esempio di uso degli attributi per modificare l'output:

```
set.seed(123)
par(mar = c(0,0,0,0))
plot(g2,
      edge.curved = 0.2,
      asp = 1,
      vertex.frame.color = "transparent",
      # dimensione dei nodi proporzionali alle frequenze
      vertex.size = V(g2)$frequency/max(V(g2)$frequency)*40,
      # spessore dei link proporzionali ai pesi
      edge.width = E(g2)$weight/max(E(g2)$weight)*10
)
```



Grafo da un dataframe

Una lista di link (*edgelist*) si presenta in questo modo:

```
# trasformiamo la matrice dell'esempio precedente
df <- tidytext::tidy(rt.fcm[1:10,1:10]) %>%
  rename(term1 = document,
         term2 = term,
         weight = count)
df
```

```
# A tibble: 52 × 3
  term1          term2          weight
  <chr>         <chr>         <dbl>
1 #greenpass    #greenpass         4
2 #greenpass    #greenpassday    303
3 #greenpassday #greenpassday     10
4 #greenpass    #greenpassrendeliberi  52
5 #greenpassday #greenpassrendeliberi 205
6 #greenpassrendeliberi #greenpassrendeliberi   2
7 #greenpass    #greenpassobbligatorio  82
8 #greenpassday #greenpassobbligatorio 303
9 #greenpassrendeliberi #greenpassobbligatorio  58
10 #greenpassobbligatorio #greenpassobbligatorio   2
# ... with 42 more rows
```

Il primo termine viene considerato come il nodo da cui parte il link, il secondo termine come quello di arrivo.

Importante è anche che la colonna con i valori delle co-occorrenze si chiami “weight”, affinché venga interpretato come sistema di pesi dalla funzione `graph_from_data_frame()`, e il grafo risulti ponderato.

```
graph_from_data_frame(df,
                      # non orientato
                      directed = F) %>%

  # semplificato
  simplify()
</code>

<code rsplus>
IGRAPH f0bcd60 UNW- 10 42 --
+ attr: name (v/c), weight (e/n)
+ edges from f0bcd60 (vertex names):
  [1] #greenpass --#greenpassday #greenpass --
#greenpassrendeliberi
  [3] #greenpass --#greenpassobbligatorio #greenpass --
#portichiusi
  [5] #greenpass --#portualiditrieste #greenpass --
#lilianasegre
  [7] #greenpass --#nogreenpass #greenpass --#libertà
  [9] #greenpass --#portualitrieste #greenpassday--
#greenpassrendeliberi
 [11] #greenpassday--#greenpassobbligatorio #greenpassday--
#portichiusi
 [13] #greenpassday--#portualiditrieste #greenpassday--
#lilianasegre
 [15] #greenpassday--#nogreenpass #greenpassday--#libertà
+ ... omitted several edges
```

In questo caso, vogliamo un grafo non orientato, quindi specifichiamo l'argomento `directed = F`, e semplifichiamo.

Script di esempio

[text_network_igraph.R](#)

```
# pacchetti
library(tidyverse)
library(quanteda)
library(igraph)
```

```
# dati
load("dati/es_twitter.rda")

# matrice delle co-occorrenze
rt.fcm <- rt2 %>%
  mutate(text = str_replace_all(text, "[\\'"]", "' ')) %>%
  corpus() %>%
  # tokenizzazione
  tokens(remove_punct = T) %>%
  # matrice documenti termini
  dfm() %>%
  # selezione dei soli hashtags
  dfm_select("#*") %>%
  # soglia di occorrenze
  dfm_trim(min_termfreq = 4) %>%
  # matrice delle cooccorrenze
  fcm()

# dalla matrice di adiacenza
g2 <- graph_from_adjacency_matrix(rt.fcm[1:10,1:10],
                                  # pesi
                                  weighted = T) %>%

  # non orientato
  as.undirected() %>%
  # semplificato
  simplify()

V(g2)$frequency <- meta(rt.fcm, "margin", "object")[1:10]

set.seed(123)
par(mar = c(0,0,0,0))
plot(g2,
      edge.curved = 0.2,
      asp = 1,
      vertex.frame.color = "transparent",
      # dimensione dei nodi proporzionali alle frequenze
      vertex.size = V(g2)$frequency/max(V(g2)$frequency)*40,
      # spessore dei link proporzionali ai pesi
      edge.width = E(g2)$weight/max(E(g2)$weight)*10
)

# dal dataframe dell'edgelist
# trasformiamo la matrice dell'esempio precedente
df <- tidytext::tidy(rt.fcm[1:10,1:10]) %>%
  rename(term1 = document,
          term2 = term,
```

```
weight = count)

graph_from_data_frame(df,
                      # non orientato
                      directed = F) %>%

# semplificato
simplify()
```

Analisi testuale, Text Network Analysis, Text Mining

1)

Quanteda prevede la costruzione di matrici di co-occorrenze (features cooccurrence matrix, `fcm()`). Se si usa **tm**, la matrice documenti-termini andrà trasformata “a mano” in una matrice termini-termini.

From:

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

Permanent link:

https://www.agnesevardanega.eu/wiki/r/analisi-testuale/network_matrice_grafo

Last update: **05/09/2025 16:53**

