

Laboratorio di Statistica Applicata - 2

Il database `movies`

Federico Plazzi

10 Novembre 2017

Il database `film.selezione`

Per prima cosa, è bene lavorare con un sottoinsieme di film per cui tutti i dati, compresi i voti, siano affidabili: estraiamo perciò tutti i film che hanno ricevuto un voto da almeno 1.000 utenti e inseriamoli in un nuovo dataframe, `film.selezione`; eliminiamo poi i film classificati come `Short`. Quali comandi bisogna usare?

Il database film.selezione

Per prima cosa, è bene lavorare con un sottoinsieme di film per cui tutti i dati, compresi i voti, siano affidabili: estraiamo perciò tutti i film che hanno ricevuto un voto da almeno 1.000 utenti e inseriamoli in un nuovo dataframe, `film.selezione`; eliminiamo poi i film classificati come `Short`. Quali comandi bisogna usare?

```
film.selezione <- movies[movies$votes >= 1000,]  
film.selezione <- film.selezione[film.selezione$Short == 0,]
```

Il database film.selezione

Per prima cosa, è bene lavorare con un sottoinsieme di film per cui tutti i dati, compresi i voti, siano affidabili: estraiamo perciò tutti i film che hanno ricevuto un voto da almeno 1.000 utenti e inseriamoli in un nuovo dataframe, `film.selezione`; eliminiamo poi i film classificati come `Short`. Quali comandi bisogna usare?

```
film.selezione <- movies[movies$votes >= 1000,]  
film.selezione <- film.selezione[film.selezione$Short == 0,]
```

D'ora in poi, lavoriamo su `film.selezione`: può convenire dare un `attach(film.selezione)`!

Esercizi di base

Gestione dei dati

- ▶ Richiamare i film con almeno 8 di voto
- ▶ Richiamare tutte le commedie o tutti i film d'animazione
- ▶ Richiamare tutti i film degli anni '70
- ▶ Richiamare tutti i film per cui la presenza dei genitori è consigliata per i bambini sotto i 10 anni di età (categoria MPAA "PG")

Elaborazioni di base

- ▶ Calcolare la media degli utenti che assegnano un voto ad un film su IMDB
- ▶ Calcolare media, varianza e deviazione standard della lunghezza dei film
- ▶ Calcolare il voto medio dei film che sono classificati in più di un genere

Esercizi avanzati

Per i padawan...

- ▶ Verificare se i film d'azione hanno dei voti significativamente maggiori delle commedie
- ▶ Verificare se i film con una qualche classificazione MPAA sono significativamente più lunghi degli altri
- ▶ Verificare se esiste una correlazione significativa tra lunghezza e voto di un film
- ▶ Verificare se le commedie di durata superiore a 110' sono significativamente di più dei film d'animazione di durata superiore a 110'

Per i maestri Jedi della statistica...

Selezionare da `film.selezione` i film classificati in un solo genere e salvarli in un nuovo dataframe, `film.per.genere`. Ci sono delle differenze significative nel budget tra i sei diversi generi? E se oltre al genere consideriamo anche il voto (<6 o ≥ 6)?