

# Assegnamento Finale - Corso di Livellamento R

Creare uno script di R e salvarlo come “Cognome\_Nome.R”. La prima riga di tale script deve essere un commento del tipo:

```
# Cognome Nome Matricola
```

Risolvere i seguenti esercizi e riportarne le soluzioni ed eventuali commenti richiesti sullo script, opportunamente commentato ed inviarlo a roberto.ascari@unimib.it entro **e non oltre** le ore 12 del 18 ottobre 2021.

## Esercizio 1

Si importi il dataset `animal.csv`, contenente informazioni su 38 specie di animali. In particolare si hanno le seguenti variabili:

1. `specie_tr`: specie dell'animale
2. `peso_corpo`: peso del corpo, in Kg
3. `peso_cerv`: peso del cervello, in grammi
4. `leggero`: numero di ore di sonno leggero (ore al giorno)
5. `profondo`: numero di ore di sonno profondo (ore al giorno)
6. `anni_vita`: speranza di vita alla nascita, in anni
7. `gestazione`: tempo di gestazione, in giorni
8. `preda`: indice qualitativo di predazione (0 = “raramente è una preda”, 1 = “è molto spesso una preda”)
9. `esposto`: indice qualitativo di esposizione durante il sonno (0 = “poco esposto”, 1 = “molto esposto”)
10. `pericolo`: indice qualitativo di pericolo (0 = “gli altri animali non rappresentano un pericolo per lui”, 1 = “gli altri animali rappresentano un grave pericolo per lui”)

**N.B.:** Prima di procedere con l'esercizio, assicurarsi che le variabili siano state importate in un formato idoneo.

- Si calcoli una nuova variabile “sonno”, rappresentante il numero totale di ore di sonno giornaliera.
- Quale animale dorme complessivamente di più? E quale dorme di meno?
- Si scelga una variabile qualitativa ( $Q$ ) e due quantitative tra quelle disponibili. Tra le due variabili quantitative scelte, si distingua tra una variabile risposta/dipendente ( $Y$ ) ed una esplicativa/indipendente ( $X$ ).
  - Si proponga un opportuno grafico per studiare la relazione tra  $Y$  ed  $X$ . Commentare il risultato.
  - Si proponga un opportuno grafico per studiare la relazione tra  $Y$  e  $Q$ . Commentare il risultato.
  - Si ritiene possibile proporre un grafico per studiare la relazione tra  $Y$  ed  $X$ , tenendo conto anche della presenza della variabile  $Q$ ? Se sì, si riporti tale grafico e lo si commenti. Altrimenti si motivi il perché non lo si ritiene possibile.

## Esercizio 2

Si considerino due variabili casuali indipendenti  $Y_1 \sim \text{Gamma}(\alpha_1, \beta)$  e  $Y_2 \sim \text{Gamma}(\alpha_2, \beta)$ , la cui generica funzione di densità è data da:

$$f(y; \alpha, \beta) = \frac{\beta^\alpha}{\Gamma(\alpha)} y^{\alpha-1} e^{-\beta y}, \quad y > 0, \alpha > 0, \beta > 0.$$

Dalla letteratura è noto che la variabile casuale

$$X = \frac{Y_1}{Y_1 + Y_2} \in (0, 1) \tag{1}$$

è distribuita come una  $\text{Beta}(\alpha_1, \alpha_2)$ , indipendentemente dal valore assunto dal parametro  $\beta$ , purché comune alle due Gamma. Per semplicità, di seguito si consideri  $\beta = 1$ . La funzione di densità di una variabile casuale  $\text{Beta}(\alpha_1, \alpha_2)$  è la seguente:

$$f(x; \alpha_1, \alpha_2) = \frac{\Gamma(\alpha_1 + \alpha_2)}{\Gamma(\alpha_1)\Gamma(\alpha_2)} x^{\alpha_1-1} (1-x)^{\alpha_2-1}, \quad x \in (0, 1), \alpha_1 > 0, \alpha_2 > 0.$$

- Implementare una **funzione** che riceva come argomenti un numero intero  $n \geq 1$  ed i numeri reali positivi  $\alpha_1$  e  $\alpha_2$ . Tale funzione dovrà generare  $n$  valori secondo la relazione (1) (estrarre quindi prima valori da  $Y_1$  ed  $Y_2$  ed utilizzarli per determinare  $X$ ). Inserire dei controlli sui sugli argomenti della funzione in modo tale che la funzione porti ad un messaggio di errore qualora l'utente scegliesse un argomento non idoneo.
- Impostare come seme per il generatore di numeri casuali la propria matricola. Si utilizzi la funzione definita al punto precedente per estrarre  $n = 2000$  osservazioni pseudo-casuali da una variabile  $\text{Beta}(5, 10)$ . Si rappresenti la distribuzione del campione estratto mediante un istogramma e si sovrainponga la funzione di densità della corrispondente Beta (utilizzare una funzione già definita in R oppure scrivere una propria funzione). Si commenti il grafico.
- Impostare una finestra grafica con due righe e due colonne. Rappresentare la funzione di densità della variabile casuale Beta, scegliendo i valori di  $\alpha_1$  e  $\alpha_2$  secondo i seguenti scenari:
  - (i)  $\alpha_1 = \alpha_2$ ;
  - (ii)  $\alpha_1 > 1$  e  $\alpha_2 < 1$ ;
  - (iii)  $\alpha_1 < 1$  e  $\alpha_2 < 1$  ( $\alpha_1 \neq \alpha_2$ );
  - (iv)  $\alpha_1 > 1$  e  $\alpha_2 > 1$  ( $\alpha_1 \neq \alpha_2$ ).

In che modo i due parametri  $\alpha_1$  e  $\alpha_2$  sembrano influenzare la distribuzione?

(N.B.: **non** viene chiesto di rappresentare anche un istogramma relativo a dati simulati.)

## Esercizio 3


Si supponga che in una stanza ci siano  $k \in \mathbb{N}$  persone. Qual è la probabilità che due di esse condividano il compleanno? Questo esercizio si ispira al 'paradosso dei compleanni' ([https://en.wikipedia.org/wiki/Birthday\\_problem](https://en.wikipedia.org/wiki/Birthday_problem)). Per rispondere a questo quesito vi viene chiesto di impostare una simulazione.

- L'utente deve poter impostare il numero  $k$  di persone nella stanza ed il numero di iterazioni.
- Per generare i compleanni casualmente, utilizzare la funzione `sample(x = 1:365, size = k, replace = T)` (per dettagli: `help(sample)`) (per semplicità si considerano unicamente anni composti da 365 giorni).

- Per stimare la probabilità, dividere il numero di scenari nei quali almeno una coppia di persone condivide il compleanno per il numero di iterazioni effettuato:

$$\hat{\text{Prob}}_k = \frac{\text{Numero scenari in cui almeno due persone su } k \text{ condividono il compleanno}}{\text{Numero scenari considerati}}$$

- Utilizzare la simulazione appena implementata per costruire un grafico che permetta di studiare come il numero  $k$  di persone nella stanza influenza la probabilità stimata che almeno due tra le  $k$  persone condividano il compleanno. Per stimare queste probabilità utilizzare almeno 20000 iterazioni. Impostare il grafico in modo tale che si considerino soltanto valori di  $k$  minori di 80. Un possibile grafico è quello riportato di seguito, ma altre rappresentazioni grafiche sono ammesse. Commentare il grafico ottenuto. Perché si parla di “paradosso dei compleanni”?



## Esercizio 4

In una foresta incantata, alla fine del giorno 0 vengono piantati 6 semi magici. Dal giorno 1 in avanti, alla fine di ogni giornata, ogni seme ha una probabilità del 50% di trasformarsi in un albero. Una volta trasformato, resterà un albero per sempre. Si implementi una simulazione per approssimare il numero **atteso** (medio) di giorni necessari affinché tutti i semi diventino degli alberi.