

Statistics - Practice

Domenico De Stefano

1 novembre 2023

1 Statistica - Esercizi 1 (Soluzioni)

Vero o Falso?

- a. Falso. L'affermazione così proposta è falsa perché non viene indicata la natura casuale del campione che stiamo prendendo in esame, né il modo in cui è stato raccolto. Non si può quindi dire se il campione riflette le caratteristiche della popolazione o se sia stato eseguito secondo le leggi della probabilità. La numerosità non è indicativa della rappresentatività del campione.
- b. Falso. Perchè non ha le stesse caratteristiche di tutta la popolazione degli studenti universitari in Italia e di conseguenza non è rappresentativo.
- c. Vero. Rappresenta la restrizione di x ad una certa modalità.
- d. Vero. La formula della densità di una classe è frequenza assoluta di Y sull'intervallo/lunghezza dell'intervallo
- e. Vero. Rappresenta il punto in cui la frequenza è maggiore, e il picco del grafico.
- f. Falso. Dipende dalla mia distribuzione. Se ad esempio esistono nelle modalità valori negativi questi potrebbero portare ad una media negativa.
- g. Falso. Essi coincidono se una distribuzione è costante o se i valori centrali della mia distribuzione sono tutti uguali.
- h. Falso. Il valore 0.5 rappresenta la posizione della mediana nelle frequenze relative cumulate.
- i. Falso. Ad esempio non può essere calcolata nelle variabili qualitative.

Esercizio 1

- a. La popolazione è rappresentata dall'insieme delle famiglie (di un comune, di una regione, ecc.) e le telefonate sono un esempio di variabile quantitativa discreta.
- b. La popolazione è composta da tutti i cittadini del comune di Trieste (possibilmente proprietari di un immobile). La lista dei cittadini è reperibile all'anagrafe ad esempio. L'ampiezza della casa di proprietà è un esempio di variabile quantitativa continua (perchè frutto di misurazione con precisione arbitrariamente crescente).
- c. La popolazione è rappresentata dai clienti di un centro commerciale. La spesa giornaliera è una variabile quantitativa discreta.

- d. La popolazione è composta da tutte le aule dell'Università di Trieste e la presenza di connessione Internet è un variabile qualitativa sconnessa (e dicotomica, dato che può assumere solo due modalità: presenza/assenza)
- e. La popolazione è costituita da tutti gli aventi diritto al voto in Italia, pertanto cittadini maggiorenni residenti in Italia. La variabile intenzioni di voto è una variabile qualitativa sconnessa (in quanto si può chiedere alle unità statistiche di esprimere una preferenza per un candidato, un partito o una coalizione).
- f. La popolazione è composta da tutti gli iscritti all'Università di Trieste. La variabile è qualitativa ordinale.
- g. La popolazione è composta dai dipendenti della regione Friuli Venezia Giulia. Variabile qualitativa ordinale.

Esercizio 2

- a. La popolazione è l'insieme delle famiglie Italiane che possiedono almeno un animale domestico
- b. Per la variabile al punto 1 le possibili modalità potrebbero essere: supermercato, negozi specializzati, negozi online, ecc.; le variabili ai punti 2, 3 e 4 si possono lasciare aperte (cioè senza predefinire alcuna modalità);
- c. L'unica variabile qualitativa è la 1 (qualitativa sconnessa)
- d. Le domande 2, 3 e 4 sono quantitative. L'unica tra queste che è continua è la 4 in quanto è una spesa media settimanale (frutto di un calcolo)
- e. In generale non sarebbe a priori sbagliato dire che per le variabili 2, 3 e 4 possiamo costruire delle distribuzioni di frequenza in classi in quanto tutte quantitative. Tuttavia dato che la 2 e la 3 sono discrete (e potrebbero assumere valori piuttosto contenuti visto il particolare oggetto di analisi), nello specifico dovremo di sicuro costruire delle classi per la variabile 4 (e valutare dopo la raccolta dati se dobbiamo costruirle anche per la 2 e la 3).

Esercizio 3 [a] Si ricordi che se scegliamo a priori il numero di classi e vogliamo che siano equiampie, una semplice formula per stabilire l'ampiezza delle classi è la seguente:

$$\text{Ampiezza} = \frac{CV}{\text{Numeroclassi}}$$

dove CV è il campo di variazione (o Range) della variabile che vogliamo ripartire in classi, ossia $CV = x_{max} - x_{min}$.

Per cui $CV = 98.6 - 11.2 = 87.4$, e dunque:

$$\text{Ampiezza} = \frac{87.4}{9} = 9.711 \approx 10$$

Un'ampiezza esatta di 9.711 è approssimabile tranquillamente a 10!

Inoltre non è necessario partire dal minimo osservato (cioè da $x_{min} = 11.2$), ma è solo necessario che il minimo sia incluso nella prima classe! Scegliamo pertanto un più “leggibile” estremo inferiore per la prima classe, ad esempio 10. Pertanto la prima classe sarà l'intervallo $(10, 20]$ (11.2 è incluso!), la seconda classe è l'intervallo $(20, 30]$, e così via fino all'ultima classe $(90, 100]$. Analogamente alla prima l'unica altra cosa da controllare è se il massimo osservato cade nell'ultima classe. Se è così la ripartizione in classi funziona.

Regola: La costruzione in classi è arbitraria per numero di classi, ampiezza delle classi (potete approssimare come volete) e scelta dell'estremo inferiore della prima classe. L'unica cosa da controllare è se il minimo e il massimo osservati ricadano rispettivamente nella prima e nell'ultima classe.

[b]

Abbiamo scelto di approssimare l'ampiezza esatta 9.711 a 10.

Esercizio 4 Per alcuni dei quesiti di questo esercizio dovranno essere usate le frequenze cumulate che servono a rispondere a questioni del tipo: quante unità statistiche hanno valori della variabile inferiore a, superiore a, ecc.

- Sono coloro che si sono collocati nella prima classe, 2 candidati (il $2/50 \times 100 = 4\%$ dei candidati)
- 18 candidati (il $18/50 \times 100 = 36\%$ dei candidati)
- Qui usiamo le frequenze cumulate, ovvero sommiamo le frequenze delle classi 450-499 e 500-549: quindi $2+18=20$ candidati (ossia $20/50 \times 100 = 40\%$ dei candidati)
- Anche qui usiamo le cumulate ma in pratica essendo 750 l'estremo superiore dell'ultima classe cumuliamo le frequenze di tutte le classi e quindi la risposta è tutti e 50 i candidati (100% dei candidati).

Esercizio 5 [a] Per completare la tabella serve l'ultima frequenza assoluta e per ricavarcela ci serve la numerosità del nostro collettivo, N . L'unico elemento che ci consente di ricavare il valore di N è l'unica frequenza relativa nota. Pertanto ricordando che la frequenza relativa della i -ma modalità di una certa variabile (o di un classe) è:

$$f_i = \frac{n_i}{N}$$

(dove n_i è la corrispondente frequenza assoluta) possiamo facilmente risolvere per N :

$$N = \frac{n_i}{f_i}$$

Nel nostro caso:

$$N = \frac{n_i}{f_i}$$

$$N = 11/0.22 = 50$$

Ora possiamo ricavare la frequenza assoluta della modalità C (che possiamo indicare ad esempio con n_C):

$$n_C = N - \sum_{i \in (A, B)} n_i$$

$$n_C = 50 - (11 + 30) = 9$$

Calcoliamo le frequenze relative delle modalità B e C, con la formula $f_i = \frac{n_i}{N}$

$$f_B = \frac{n_B}{N} = \frac{30}{50} = 0.6$$

$$f_C = \frac{n_C}{N} = \frac{9}{50} = 0.18$$

La percentuale della i -ma modalità corrisponde alla i -ma frequenza relativa moltiplicata per 100:

$$\%f_A = \left(\frac{n_A}{N}\right) \times 100 = \left(\frac{11}{50}\right) \times 100 = 22\%$$

$$\%f_B = \left(\frac{n_B}{N}\right) \times 100 = \left(\frac{30}{50}\right) \times 100 = 60\%$$


$$\%f_C = \left(\frac{n_C}{N}\right) \times 100 = \left(\frac{9}{50}\right) \times 100 = 18\%$$

La tabella completa

Modalità	n_i	f_i	%
A	11	0.22	22
B	30	0.6	60
C	9	0.18	18

[b]

Per costruire un diagramma a barre per una variabile qualitativa sconnessa si riporta semplicemente la frequenza assoluta (o relativa o la percentuale) sull'asse delle Y e le modalita' della variabile sull'asse delle X . Si tracciano poi delle barre di altezza proporzionale alla frequenza scelta




[c]

Per costruire il grafico a torta riportiamo le frequenze assolute (meglio le relative!) su scala dei gradi sessagesimali (cioè in 360°), in modo da calcolare l'ampiezza dell'angolo proporzionale alla frequenza da riprodurre nel grafico:

$$\text{Angolo}_A = f_A \times 360 = 79.2$$

$$\text{Angolo}_B = f_B \times 360 = 216$$

$$\text{Angolo}_C = f_C \times 360 = 64.8$$



Exercise 6 [a.]

Le unità statistiche sono le 3756 imprese sulle quali è stato rilevato il costo del lavoro sostenuto.

[b.]

Per calcolare le frequenze assolute occorre ricordarsi la definizione di densità e fare attenzione che queste, nel caso specifico, sono state calcolate dalle frequenze relative.

Pertanto la formula da considerare per l' i -ma classe è:

$$\text{densità}_i = \frac{f_i}{\text{ampiezza}_i}$$

per cui è facile ricavare tutte le frequenze relative e per differenza la frequenza mancante (e da quella la densità mancante). Nota: le densità non sommano a 1, le frequenze relative sì!

$$f_i = \text{densità}_i \times \text{ampiezza}$$

e dunque per le prime tre classi:

$$\begin{aligned} f_1 &= 0.0125 \times (12 - 0) = 0.15 \\ f_2 &= 0.02 \times (30 - 12) = 0.02 \times 18 = 0.36 \\ f_3 &= 0.02 \times (50 - 30) = 0.02 \times 20 = 0.4 \end{aligned}$$

La frequenza relativa mancante per la quarta classe è dunque: $1 - (0.15 + 0.36 + 0.4) = 0.09$

E la corrispondente densità:

$$\text{densità}_4 = \frac{0.09}{100 - 50} = 0.002$$

Pertanto la tabella completa sarà:

Costo lav.	Densità di frequenza relativa	frequenza relativa	frequenza assoluta
(0, 12]	0.0125	0.15	$0.15 \times 3756 = 564$
(12, 30]	0.02	0.36	$0.36 \times 3756 = 1352$
(30, 50]	0.02	0.4	$0.4 \times 3756 = 1502$
(50, 100]	0.0018	0.09	$0.09 \times 3756 = 338$


[c]

I valori centrali sono:


$$\begin{aligned} x_1 &= \frac{0+12}{2} = 6 \\ x_2 &= \frac{12+30}{2} = 21 \\ x_3 &= \frac{30+50}{2} = 40 \\ x_4 &= \frac{50+100}{2} = 75 \end{aligned}$$

[d]

Il grafico corretto è l'istogramma (con ampiezza diversa per le varie classi):



Esercizio 7 [a] Il grafico più opportuno è quello a barre:



[b]

	<i>SP</i>	<i>EC</i>	<i>n_i</i>	<i>N_i</i>
1	14	9	23	23
2	6	5	11	34
3	4	6	10	44
4	4	4	8	52
5	2	3	5	57

$$M_e = \frac{N+1}{2} = \frac{58}{2} = X_{29} = 2$$

$$Q_1 = \frac{N+1}{4} \cdot 1 = \frac{57+1}{4} \cdot 1 = X_{14} = 1$$

$$Q_3 = \frac{N+1}{4} \cdot 3 = \frac{57+1}{4} \cdot 3 = X_{43} = 3$$

[c]

	<i>SP</i>	<i>EC</i>	<i>n_i</i>	<i>N_i</i>	<i>F_i</i>
1	14	9	23	23	23/57 = 0,4
2	6	5	11	34	34/57 = 0,6
3	4	6	10	44	44/57 = 0,8
4	4	4	8	52	52/57 = 0,9
5	2	3	5	57	57/57 = 1

Esercizio 8 [a]


Scegliamo lo stesso numero di classi e la stessa ampiezza per entrambe le distribuzioni condizionate all'impresa. In particolare scegliamo un'ampiezza di 100 (ore).

Qui mostriamo solo la distribuzione percentuale (equivalenti alle frequenze relative).

Durata (in ore)	% Azienda A	% Azienda B
[650, 750)	10.0	0.0
[750, 850)	10.0	5.0
[850, 950)	50.0	20.0
[950, 1050)	22.5	40.0
[1050, 1150)	7.5	22.5
[1150, 1250)	0.0	12.5

[b]

Histogram of Manufacturer_A **Histogram of Manufacturer_B**



[c]

La distribuzione della durata delle lampadine dell'azienda A sembra più concentrata verso durate inferiori rispetto a quella dell'azienda B (ad esempio l'azienda B non ha nessuna lampadina che dura tra le 650 e le 750 ore, a fronte di un 10% di lampadine in quella classe per l'azienda A)

[d]

Il confronto è ancor più evidente usando le frequenze cumulate

Durata (in ore)	% Azienda A	% Azienda B
[650, 750)	10.0	0.0
[750, 850)	20.0	5.0
[850, 950)	70.0	25.0
[950, 1050)	92.5	65.0
[1050, 1150)	100.0	87.5
[1150, 1250)	100.0	100.0

... che possono anche essere rappresentate graficamente (volendo)




Figura 1: Istogrammi delle distribuzioni percentuali cumulate della durata delle lampadine dell'azienda A (a sinistra) e dell'azienda B (a destra).

Dall'analisi delle frequenze (percentuali) cumulate, sembra che l'azienda B produca lampadine migliori dell'azienda A. Infatti la percentuale cumulata per l'azienda B mostra infatti che il 65% delle sue lampadine durano meno di 1050 ore, mentre il 70% di lampadine dell'azienda A, durano meno di 950 ore. Inoltre nessuna lampadina dell'azienda A dura più di 1150 ore, invece il 12.5% di quelle dell'azienda B durano tra le 1150 e le 1250 ore (provate anche a calcolare qualche indice per verificare se danno la stessa informazione)