

## La stima della frequenza di risposte casualizzate

### mediante domanda incorrelata

Un argomento che potrebbe essere trattato come tematica di approfondimento in una Unità Didattica dedicata al Calcolo delle Probabilità è una particolare applicazione dei teoremi delle probabilità totali e composte, nota come “Metodo delle risposte casualizzate a domanda incorrelata” o “Schema di Simmons”. Tale tecnica viene sovente utilizzata in indagini di statistica sociale e mira a ricavare informazioni attendibili su argomenti delicati (ad es., uso di droga, attitudini sessuali, redditi effettivi, ecc.).

#### Schema operativo

Si supponga che  $P_X$  sia la frequenza con cui una caratteristica delicata  $X$  sia presente in una data popolazione  $U$ ; mentre  $P_K$  è la frequenza con cui si presenta nella stessa popolazione un attributo  $K$ , incorrelato con  $X$ , che può essere dichiarato senza alcuna riserva (ad es.  $K$  è un numero telefonico che finisce con una certa cifra, il colore dei capelli o degli occhi, ...).

Lo schema di rilevazione prende le mosse consegnando all'intervistato un'urna contenente un certo numero di palline bianche e nere e gli si chiede di rispondere (segnandolo su una scheda) con un “sì” oppure con un “no” alla domanda delicata, se dall'urna pesca pallina bianca; mentre risponderà con un “sì” oppure con un “no” al possesso dell'attributo  $K$ , se dall'urna pesca pallina nera. Poiché solo l'intervistato conosce il risultato dell'estrazione dall'urna, solo lui conosce se il “sì” oppure il “no” è attribuito alla domanda delicata  $X$  oppure all'attributo  $K$ : ciò dovrebbe indurre l'intervistato a non dichiarare il falso, in quanto, essendo noto solo a lui il significato del “sì” o del “no” dato, ha la garanzia di non palesare la sua situazione personale.

#### Metodologia di applicazione

Ipotizziamo di utilizzare per la nostra rilevazione un'urna contenente 12 palline bianche e 6 nere e che venga richiesto ai nostri intervistati di rispondere al quesito delicato “*fai o hai mai fatto uso di stupefacenti?*”, se pesca dall'urna pallina bianca; e alla domanda “*il tuo numero di telefono finisce con la cifra 5?*”, se pesca pallina nera.

Indicando con:

$\lambda = 2/3$  ( $P_B$ ) la probabilità di estrarre dall'urna di pallina bianca;

$1 - \lambda = 1/3$  ( $1 - P_B$ ) la probabilità di estrarre pallina nera;

$P_X$  (incognita) la probabilità di rispondere “sì” alla domanda delicata (di possedere la caratteristica  $X$ )

$1 - P_X$  (incognita) la probabilità di non possedere la caratteristica  $X$ ;

$P_K = 1/10 = 0,1$  la probabilità che il proprio numero telefonico termini con la cifra 5;

$1 - P_K = 0,9$  la probabilità che il proprio numero telefonico **non** termini con la cifra 5;

si può impostare il cosiddetto **Schema di Simmons**, che fornisce le possibili risposte, in relazione al gruppo di appartenenza e al risultato dell'esperimento aleatorio (nel caso di campionamento casuale):

### Schema di Simmons

Eventi Composti	Probabilità	Risposta alla domanda "delicata"	Risposta alla domanda sul n° tel.
		Gruppo che ha estratto pallina bianca	Gruppo che ha estratto pallina nera
		$\lambda = 2/3$	$1 - \lambda = 1/3$ <sup>(1)</sup>
$X \cap K$	$P_X \cdot P_K$	SI	SI
$\bar{X} \cap K$	$P_X \cdot (1 - P_K)$	SI	NO
$X \cap \bar{K}$	$(1 - P_X) \cdot P_K$	NO	SI
$\bar{X} \cap \bar{K}$	$(1 - P_X) \cdot (1 - P_K)$	NO	NO

(1) Attenzione a non confondere questa probabilità (prob. di estrarre pallina nera - risposta alla domanda non "delicata"), con quella di avere il n° di telefono che termina con 5 (= 1/10 = 0,1).

In cui:

**X**  $\Rightarrow$  Possiede la caratteristica delicata X (uso di droga);

**$\bar{X}$**   $\Rightarrow$  Non possiede la caratteristica X (non uso di droga);

**K**  $\Rightarrow$  Possiede l'attributo K (n° tel. termina con 5);

**$\bar{K}$**   $\Rightarrow$  Non possiede l'attributo K (n° tel. non termina con 5).

Applicando congiuntamente i principi delle probabilità totali (per eventi incompatibili) e composte (per eventi indipendenti), dalla tabella (nell'incrocio righe/colonne in cui compare la risposta "si") si ricava la probabilità, indicata con **p**, che in una prova la risposta alla domanda delicata X o al possesso dell'attributo K, sia positiva:

$$p = \lambda \cdot P_X \cdot P_K + \lambda \cdot P_X \cdot (1 - P_K) + (1 - \lambda) \cdot P_X \cdot P_K + (1 - \lambda) \cdot (1 - P_X) \cdot P_K;$$

dalla quale, svolgendo i prodotti e semplificando, si ottiene:

$$p = \lambda \cdot P_X + (1 - \lambda) \cdot P_K \Rightarrow \lambda \cdot P_X = p - (1 - \lambda) \cdot P_K \Rightarrow$$

$$\Rightarrow P_X = \frac{p - P_K(1 - \lambda)}{\lambda};$$

Se si indica ora con **x** il numero delle risposte affermative ottenute su **n** unità campionarie, la frequenza **f = x/n** delle risposte positive sul totale degli intervistati, può essere considerata una

stima del valore teorico  $\rho$ . Sostituendo, quindi, il valore di  $f$  nella relazione precedente si ottiene la corrispondente stima (corretta e consistente) della probabilità  $P_X$  di risposta affermativa alla domanda delicata (nel nostro es. uso di droga):

$$\hat{P}_X = \frac{f - P_K(1 - \lambda)}{\lambda}; \quad (*)$$

in cui  $P_K$  e  $\lambda$  sono costanti note.

### Osservazione

La distribuzione campionaria di  $P_X$ , al crescere di  $n$ , tende alla normalità con media  $\rho$  e varianza  $\sigma^2(\hat{P}_X) = \frac{\rho(1-\rho)}{n\lambda^2}$ ; una cui stima, tenuto conto che  $f$  è una stima di  $\rho$ , è data da:

$$\hat{S}^2(\hat{P}_X) = \frac{f(1-f)}{(n-1)\lambda^2}$$

Se si utilizza lo stesso schema di estrazione, la quantità  $(1 - \lambda) \cdot P_K$  diventa una costante e la stima della probabilità di risposta "sì" a un qualsivoglia quesito delicato si può ottenere in modo immediato, sostituendo nella (\*) il valore della frequenza delle risposte positive rilevate.

### Esempio

Utilizzando lo schema di estrazione precedente (un'urna contenente 6 palline nere e 12 bianche), nell'ipotesi che siano state rilevate  $x = 50$  risposte affermative, su un totale di  $n = 120$  intervistati, si ha:

$$\lambda = 12/18 = 0.67; \quad 1-\lambda = 6/18 = 0.33;$$

$$f = x/n = 50/120 = 0.42; \quad P_K = 1/10 = 0.1.$$

La stima di  $P_X$  sarà, quindi:

$$\hat{P}_X = \frac{0.42 - 0.1 * 0.33}{0.67} = \frac{0.42 - 0.033}{0.67} = 0.575;$$

con varianza stimata:

$$\hat{S}^2(\hat{P}_X) = \frac{0.42(1-0.42)}{119 * 0.67^2} = \frac{0.2436}{53.42} = 0.005;$$

ovvero, la probabilità di presenza della caratteristica delicata  $X$  (nel nostro caso uso di droga) nel nostro campione è del 57.5%, con una variabilità dello 0.5%.

Da notare che la stessa frequenza di risposte "sì" (ad es.  $f = 50/120 = 0.42$ ), conduce ad una stima differente di  $P_X$  (prob. di possedere la caratteristica delicata  $X$ ), se viene cambiato lo schema di

estrazione. Infatti, se cambia la composizione dell'urna, cambiano, di conseguenza, anche le probabilità di rispondere all'uno o all'altro quesito (caratteristica delicata o attributo incorrelato); se, invece, cambia la probabilità di risposta al quesito sul possesso dell'attributo K, varia il peso di tale probabilità nel calcolo della stima di  $P_X$ .

### Esempio

- Se cambia la composizione dell'urna:

4 palline nere – 6 bianche

$$\lambda = 6/10 = 0.6; \quad 1-\lambda = 4/10 = 0.4;$$

$$f = x/n = 50/120 = 0.42; \quad P_K = 1/10 = 0.1;$$

$$\hat{P}_X = \frac{0.42 - 0.1 * 0.4}{0.6} = \frac{0.42 - 0.04}{0.6} = 0.63;$$

ovvero, il 63% possiede la caratteristica X.

- Se cambia la probabilità dell'attributo K; ad esempio, in caso di estrazione di pallina nera, rispondere alla domanda: "hai gli occhi azzurri?"; si ha:

$$\lambda = 12/18 = 0.67; \quad 1-\lambda = 6/18 = 0.33;$$

$$f = x/n = 50/120 = 0.42; \quad P_K = 1/4 = 0.25;$$

$$\hat{P}_X = \frac{0.42 - 0.25 * 0.33}{0.67} = \frac{0.42 - 0.0825}{0.67} = 0.504;$$

cioè il 50,4% possiede la caratteristica X.

### Osservazione

Si può verificare (anche empiricamente) che, utilizzando lo stesso schema di estrazione, da un certo "livello soglia" di frequenze di risposte "si", la probabilità che la popolazione di intervistati possieda la caratteristica "delicata" X è sicuramente pari ad Uno (100%). Nell'esempio dello schema di estrazione qui utilizzato, se il n° di risposte "si" è prossimo al 70%, possiamo essere certi che la caratteristica X è posseduta da tutti gli intervistati:

$$\hat{P}_X = \frac{0.7 - 0.1 * 0.33}{0.67} = \frac{0.7 - 0.033}{0.67} = 1.$$