

Esame di MQAT / Statistica del 2-2-2011

Nome / Mail :

- 1) Si calcoli il tasso medio di laureati a Venezia in base alla tabella di dati

Localita'	% Laureati	Popolazione
Rialto	0.09	70000
Mestre	0.04	150000
Lido	0.06	30000

- 2) Data la distribuzione Normale $x \sim N(\mu = 3, \sigma^2 = 4)$ ed un campione di dimensione $n = 9$, calcolare la probabilita' condizionata $P(\bar{x}_n < 2 \mid \bar{x}_n < 3.5)$
- 3) Data la distribuzione Bernoulliana $x \sim B(\pi = 1/3)$ ed un campione di $n = 3$ osservazioni, calcolare la distorsione e l'efficienza della statistica $\tilde{x} = (\frac{1}{6}x_1 + \frac{2}{6}x_2 - \frac{3}{6}x_3)$ come stimatore per π . E' \tilde{x} corretto e consistente ?
- 4) Si consideri la tabella di frequenze dell'Esercizio 6.15. Supponendo che l'indice di associazione di Pearson abbia fornito il valore $W = 8.21$, si chiede di verificare la sua significativita' con un test χ^2 al 90% e valutare l'indice di Cramer.
- 5) Due campioni di dimensioni $n_x = 10$, $n_y = 15$ sul valore di immobili di tipo X e Y ha fornito le somme $\sum_i x_i = 20$, $\sum_i y_i = 45$ e $\sum_i x_i^2 = 50$, $\sum_i y_i^2 = 165$. Calcolare le medie e la varianza "pooled", costruire un intervallo di confidenza al 90 % per la differenza delle medie e verificare l'ipotesi $\delta = \mu_y - \mu_x = 2$.
- 6) Si consideri la serie y_t in Figura 5.2.2. Le regressioni sui primi 6 dati sono

$$\text{trend lineare } y_t = 576 - 0.29 x_t + e_t, \quad S_e = 0.79 \quad (1)$$

$$\text{auto regress. } y_t = .97 y_{t-1} + u_t, \quad S_u = 1.20 \quad (2)$$

dove $x_t = 2001 \dots 2006$ e $t = 1 \dots 6$. Quale e' il modello migliore ?

Dalla Figura 5.2.2 gli ultimi valori sono $y_6 = 3.8$ e $y_7 = 4.8$. Si chiede di calcolare le previsionsi per l'anno $x_7 = 2007$ ed il relativo intervallo di confidenza al 95%. Quale e' il modello migliore ? Le due previsionsi sono compatibili ?

Soluzioni

1) la variabile X e' la % dei laureati, e bisogna calcolarne la media ponderata coi pesi f_j della popolazione: $\bar{X}=.09*(7/25)+.04*(15/25)+.06*(3/25)=0.0564$

2) la variabile e' $\bar{x}_n \sim N(3, 4/9)$, avendo $(x < 2) \cap (x < 3.5) = (x < 2)$, la probabilita' cercata e' $P(\bar{x}_n < 2)/P(\bar{x}_n < 3.5)$ e standardizzando $P(z < -1.5)/P(z < 0.75)$

3) per la Distorsione bisogna calcolare $E(\tilde{x}) = \mu/6 + \mu/3 - \mu/2=0$, poiche' $\mu = \pi=1/3$, la distorsione e' quindi $D(\tilde{x})=-1/3$. Per l'Efficenza bisogna calcolare la varianza $V(\tilde{x}) = \sigma^2/6^2 + \sigma^2/3^2 + \sigma^2/2^2=0.086$, essendo $\sigma^2 = \pi(1 - \pi) = .22$, che e' maggiore di $V(\bar{x}_3)=.22/3$. Quindi lo stimatore \tilde{x} e' distorto ed inefficiente.

4) la tabella ha dimensione 3×4 e $n=69$, quindi la statistica di Pearson W_n ha distribuzione $\chi^2(2 * 3)$. Il valore critico al 90% e' $\chi_{.10}^2(6)=10.6 > 8.21=W_n$ e quindi ci accetta l'ipotesi di indipendenza tra i caratteri. L'indice di Cramer $V = \sqrt{8.21/(69 * 2)}=.24$ e' basso.

5) dalle somme si calcolano $\bar{x}=2$, $\bar{y}=3$, $S_x^2=50/10-4=1$, $S_y^2=2$. La varianza *pooled* e' la media ponderata (per le dimensioni campionarie) delle due $S_p^2=1*10/25 + 2*15/25=1.6$. L'intervallo di confidenza esatto al 90% per la differenza delle medie (supponendo x, y normali e $\sigma_x = \sigma_y$) usera' la studente $t_{.05}(10+15-2)=1.7$, da cui

$$\hat{\delta}_{1,2} = (3 - 2) \pm 1.7\sqrt{1.6/10 + 1.6/15} = [0.12, 1.88]$$

si rifiutano le ipotesi $\mu_x = \mu_y$ ma anche $\delta=2$. Al 95% invece si accettano

6) il modello migliore e' il primo perche' ha varianza dei residui S_e piu' bassa; le due previsioni saranno $\hat{y}_7=576-.29*2007=-6$, e $\hat{y}_7=.97*3.8=3.7$. Quella che piu' si avvicina al valore reale $y_7=4.8$ e' la seconda. Gli intervalli di confidenza approssimati saranno $\hat{y}_7 \pm 2 * S$, quindi $[-7.6, -4.4]$, $[1.3, 6.1]$ che sono incompatibili non avendo punti in comune e solo il secondo include il vero y_7 .