

DATOS en una RED

Parte 1 : Autocorrelacion

Marzo 2019

Consecuencia de la autocorrelacion

X_1, X_2, \dots, X_n sucesión de v.a. correlacionadas,

$$\text{Var}(X_i) = \sigma^2, \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

- $\text{Var}(\bar{X}) > \frac{\sigma^2}{n}$ si $\text{cov}(X_i, X_j) > 0$
- $\text{Var}(\bar{X}) < \frac{\sigma^2}{n}$ si $\text{cov}(X_i, X_j) < 0$

Consecuencias


- los intervalos de confianza pueden ser mayores o menores que en el caso independiente
- las p -values de prueba para dos muestras pueden ser mayores o menores que en el caso independiente.

Consecuencia de la autocorrelacion

Ejemplo 1

$$X_t = \rho X_{t-1} + \varepsilon_t \quad |\rho| < 1 \quad \text{cov}(X_t, X_{t+h}) = \sigma_X^2 \rho^h$$

$$V(\bar{X}) = \frac{\sigma_X^2}{n} \left(1 + 2\left(\frac{\rho}{1-\rho}\right)\left(1 - \frac{1}{n}\right) - 2\left(\frac{\rho}{1-\rho}\right)^2 \left(\frac{1-\rho^{n-1}}{n}\right) \right) = \lambda \frac{\sigma_X^2}{n}$$



Intervalos de confianza de nivel 95%

$$n=10, \rho = 0.25, \lambda = 1.67, I = [\bar{x} - 2.49 \frac{\sigma}{\sqrt{n}} ; \bar{x} + 2.49 \frac{\sigma}{\sqrt{n}}]$$

$$n=10, \rho = -0.25, \lambda = 0.63, I = [\bar{x} - 1.23 \frac{\sigma}{\sqrt{n}} ; \bar{x} + 1.23 \frac{\sigma}{\sqrt{n}}]$$

Consecuencia de la autocorrelacion

Ejemplo 2


$$X^i \sim \mathcal{N}(\mu_i, \sigma), X_t^i = \rho_i X_{t-1}^i + \varepsilon_t^i \quad i = 1, 2 \quad t = 1, T_i$$

Prueba de dos muestras : $H_0: \mu_1 = \mu_2$ contra $H_1: \mu_1 \neq \mu_2$

Si las muestras son independientes


$$Z = \frac{\overline{X^1} - \overline{X^2}}{S \sqrt{\frac{1}{T_1} + \frac{1}{T_2}}} \sim \mathcal{T}(T_1 + T_2 - 2), R = \{|Z| > z\}$$

Caso dependiente: estimacion de \hat{q} cuantil de nivel 95% (simulacion)



Autocorrelacion espacial

Paris: prix des logements au m² (2009)



Vecindad

$S = (s_i)_{i=1,n}$, nodos (lugares) de D .

Grafo \mathcal{G} : relacion binaria de $S \times S$: s_i esta relacionado con s_j .

Matriz W de adyacencia: matriz cuadrada de tamaño n^2

$$w_{ij} = \begin{cases} 0 & \text{si } s_i = s_j \\ 0 & \text{si } (s_i, s_j) \notin \mathcal{G} \end{cases}$$

Ejemplos

W con coeficientes binarios


$$w_{ij} = \begin{cases} 1 & \text{si } (s_i, s_j) \in \mathcal{G} \\ 0 & \text{sino} \end{cases}$$

W con coeficientes basados en las distancias

$$w_{ij} = \begin{cases} \frac{1}{d_{ij}} & \text{si } (s_i, s_j) \in \mathcal{G} \\ 0 & \text{sino} \end{cases} \quad d_{ij} = \text{dist}(s_i, s_j)$$


Vecindad

Voisinages par triangulation




Vecindad

Voisinages par 4-plus proches voisins



Vecindad

Voisinages par plus petites distances (<60)



Vecindad

$$S_0 = \sum_{i \neq j} w_{ij} \quad S_1 = \frac{1}{2} \sum_{i \neq j} (w_{ij} + w_{ji})^2 \quad S_2 = \sum_{i=1}^n (w_{i+} + w_{+i})^2$$

Characteristics of weights list object:

Neighbour list object:

Number of regions: 80

Number of nonzero links: 446

Percentage nonzero weights: 6.96875

Average number of links: 5.575

Weights style: B

Weights constants summary:

n	nn	S0	S1	S2
B	80	6400	446	892
				10304

Datos binarios

$Z_i = Z(s_i) = 0$ (blanco) o 1 (negro) , $P(Z_i = 1) = p$

$$NN = \frac{1}{2} \sum_{i,j} w_{ij} Z_i Z_j \text{ numero de pares de vecinos negros}$$

$$NB = \frac{1}{2} \sum_{i,j} w_{ij} (Z_i - Z_j)^2 \text{ numero de pares de vecinos blanco-negro}$$

$$BB = \frac{1}{2} \sum_{i,j} w_{ij} - NN - NB$$

Distribucion bajo la hipotesis de independencia :

- modelo binomial : $\mathcal{B}(n, p)$
- modelo hypergeometrico : $\mathcal{H}(n, n_1)$

Calculo de los momentos

$$R = \sum_{i \neq j} w_{ij} Y_{ij}$$

$$\mathbb{E}(R) = \sum_{i \neq j} w_{ij} \mathbb{E}(Y_{ij})$$

$$\begin{aligned}\mathbb{V}(R) &= \sum_{i \neq j} w_{ij} (w_{ij} + w_{ji}) \mathbb{V}(Y_{ij}) \\ &\quad + \sum_{i \neq j \neq k} (w_{ij} + w_{ji})(w_{ik} + w_{ki}) \text{cov}(Y_{ij}, Y_{ik}) \\ &\quad + \sum_{i \neq j \neq k \neq \ell} w_{ij} w_{k\ell} \text{cov}(Y_{ij}, Y_{k\ell})\end{aligned}$$

Calculo de los momentos

Modelo binomial :

$$E(NN) = \frac{1}{2}S_0p^2$$

$$V(NN) = \frac{1}{4} \left(S_1(p^2 - p^4) + (S_2 - 2S_1)(p^3 - p^4) \right)$$

$$E(BN) = S_0p(1-p),$$

$$V(BN) = S_1p(1-p) + \frac{1}{4} \left(S_2p(1-p)(1-4p(1-p)) \right)$$

Modelo hypergeometrico : $n^{(p)} = \frac{n!}{(n-p)!}$

$$E(NN) = \frac{1}{2}S_0 \frac{n_1^{(2)}}{n^{(2)}}$$

$$4V(NN) = S_1 \left(\frac{n_1^{(2)}}{n^{(2)}} - 2 \frac{n_1^{(3)}}{n^{(3)}} + \frac{n_1^{(4)}}{n^{(4)}} \right) + S_2 \left(\frac{n_1^{(3)}}{n^{(3)}} - \frac{n_1^{(4)}}{n^{(4)}} \right) + S_0^2 \frac{n_1^{(4)}}{n^{(4)}} - \left(S_0 \frac{n_1^{(2)}}{n^{(2)}} \right)^2$$

Prueba de independencia

Teorema

Si los Y_{ij} estan uniformemente acotados en D entonces la estadistica $R = \sum_{i \neq j} w_{ij} Y_{ij}$ converge a una distribucion de probabilidad normal si $S_0^{-2} \text{Var}(R)$ es exactamente de orden n^{-1} .

Comentario


- La condicion se verifica para grillas regulares, o si el numero de vecinos esta uniformemente acotado.
- Este resultado da una estadistica de prueba en el caso binomial.

Prueba por permutaciones

- repartir aleatoriamente n_1 celdas negras y $n - n_1$ celdas blancas,
- determinar las distribuciones empiricas de BB , BN , NN ,
- comparar con los valores observados.

Datos binarios

Paris: prix des logements au m² (2009)



$$\begin{aligned}B &= 42 \\N &= 38 \\NN &= 65 \\BB &= 80\end{aligned}$$

Prueba de independencia

Join count test under nonfree sampling

Std. deviate for faible = 4.3687, p-value = 6.251e-06
sample estimates:

Same colour statistic	Expectation	Variance
80.00000	60.76044	19.39523

Join count test under nonfree sampling

Std. deviate for fort = 3.6039, p-value = 0.0001568
sample estimates:

Same colour statistic	Expectation	Variance
65.00000	49.61044	18.23553

Calculo de los momentos

Monte-Carlo simulation of join-count statistic

number of simulations + 1: 101

Join-count statistic for faible = 80,

rank of observed statistic = 101,

p-value = 0.009901

sample estimates:

mean of simulation variance of simulation

60.82000	17.26020
----------	----------

Join-count statistic for fort = 65,

rank of observed statistic = 101,

p-value = 0.009901

sample estimates:

mean of simulation variance of simulation

48.84000	18.29737
----------	----------

Indice de Moran

Z un campo aleatorio real, dotado de un grafo de vecindad

Indice de Moran:

$$I = \frac{n}{\sum_{i \neq j} w_{ij}} \frac{\sum_{i,j} w_{ij}(Z_i - \bar{Z})(Z_j - \bar{Z})}{\sum_i (Z_i - \bar{Z})^2}$$

si $I > 0$ hay correlacion positiva (clusters)

si $I < 0$ hay correlacion negativa (repulsion)

si $I \approx 0$ no hay correlacion

Indice de Geary

Indice de Geary:

$$C = \frac{n-1}{2 \sum_{i \neq j} w_{ij}} \frac{\sum_{i,j} w_{ij} (Z_i - Z_j)^2}{\sum_i (Z_i - \bar{Z})^2}$$

si $C \approx 0$ hay correlacion positiva (clusters)

si $C \gg 0$ hay correlacion negativa (repulsion)

Distribucion bajo la hipotesis de independencia

- modelo Gaussiano : $Z_i \sim \mathcal{N}(\mu, \sigma)$
- modelo remuestrado : $Z_i \in \{z_1, z_2, \dots, z_n\}$ equiprobables

Teorema

Si (X_1, \dots, X_n) i.i.d, $X_i \sim \mathcal{N}(0, 1)$ y $h : \mathbb{R}^n \rightarrow \mathbb{R}$ es invariante por cambio de escala, entonces $h(X_1, \dots, X_n)$ es independiente de $Q = \sum_{i=1}^n X_i^2$.

Calculo de los momentos

Indice de Moran

- modelo Gaussiano

$$E(I) = -\frac{1}{n-1}$$

$$V(I) = \frac{1}{(n-1)(n+1)S_0^2} (n^2 S_1 - n S_2 + 3S_0^2) - \frac{1}{(n-1)^2}$$

- modelo remuestrado

$$E(I) = -\frac{1}{n-1}$$

$$\begin{aligned} V(I) &= \frac{1}{(n-1)^{(3)}S_0^2} \left(n((n^2 - 3n + 3)S_1 - nS_2 + 3S_0^2) \right. \\ &\quad \left. - b_2((n^2 - n)S_1 - 2nS_2 + 6S_0^2) \right) - \frac{1}{(n-1)^2} \end{aligned}$$

$$b_2 = \frac{m_4}{m_2^2} \quad nm_4 = \sum_i (z_i - \bar{z})^4$$

Calculo de los momentos

Indice de Geary

- modelo Gaussiano

$$E(C) = 1$$

$$V(C) = \frac{2(S_1 + S_2)(n - 1) - 4S_0^2}{2(n + 1)S_0^2}$$

- modelo remuestrado

$$E(C) = 1$$

$$\begin{aligned} V(C) &= \frac{1}{n(n-1)^{(2)}S_0^2} \left((n-1)S_1(n^2 - 3n + 3 - (n-1)b_2) \right. \\ &\quad - \frac{1}{4}(n-1)S_2(n^2 + 3n - 6 - (n^2 - n + 2)b_2) \\ &\quad \left. + S_0^2(n^2 - 3 - (n-1)^2b_2) \right) \end{aligned}$$

Prueba de independencia

Teorema

λ_i son los valores propios de la matriz de adyacencia W . Si

$$\frac{\sum_i \lambda_i^j}{\left(\sum_i \lambda_i^2\right)^{1/2}} = o(1) \text{ para } j = 1, \dots \text{ entonces bajo el modelo}$$

Gaussiano los indices I y C convergen en distribucion a una distribucion normal. Este resultado sigue siendo verdadero si las variables no son gaussianas pero de momento de orden 4 finito.

Comentario Si W est esymetrica, el numero de vecinos esta uniformemente acotado y $0 < \lim \frac{S_1}{n} < \infty$ entonces la condicion del teorema se verifica.

Prueba por permutaciones

- repartir aleatoriamente los valores observados,
- deducir las distribuciones empiricas de I et C ,
- comparar con los valores observados.

Pruebas Moran et Geary

Moran's I test under normality

Moran I statistic standard deviate = 6.8281,
p-value = 4.301e-12

alternative hypothesis: greater sample

estimates:	Moran I statistic	Expectation	Variance
	0.42700	-0.01266	0.00415

Geary's C test under normality

Geary C statistic standard deviate = 5.5842,
p-value = 1.174e-08

alternative hypothesis: Expectation greater than statistic
estimates: Geary C statistic Expectation Variance

	0.60739	1.00000	0.00494
--	---------	---------	---------

Pruebas Moran et Geary

Moran's I test under randomisation

Moran I statistic standard deviate = 6.8754,
p-value = 3.091e-12

estimates:	Moran I statistic	Expectation	Variance
	0.42700	-0.01266	0.00409

Geary's C test under randomisation

Geary C statistic standard deviate = 5.3571,
p-value = 4.227e-08

estimates:	Geary C statistic	Expectation	Variance
	0.60739	1.00000	0.00537

Pruebas Moran et Geary

Monte-Carlo simulation of Moran's I

number of simulations + 1: 101

statistic = 0.427

observed rank = 101, p-value = 0.009901

alternative hypothesis: greater

Monte-Carlo simulation of Geary's C

number of simulations + 1: 101

statistic = 0.6074

observed rank = 1, p-value = 0.009901

alternative hypothesis: less

Correlograma espacial

Vecindad de orden k

$w_{ij}^{(k)} = 1$ si s_i y s_j son vecinos de orden k

$w_{ij}^{(k)} = \frac{1}{d_{ij}}$ si $d_{ij} \in$ clase de distancia k

$$I(k) = \frac{n}{\sum_{i,j} w_{ij}^{(k)}} \frac{\sum_{i,j} w_{ij}^{(k)} (Z_i - \bar{Z})(Z_j - \bar{Z})}{\sum_i (Z_i - \bar{Z})^2}$$

Correlograma espacial

Spatial correlogram for prixm2

method: Moran's I

	estimate	expectation	variance	sd	Pr(I)	
1	0.42495941	-0.01265823	0.00512735	6.1115	9.869e-10	***
2	0.24510554	-0.01265823	0.00249602	5.1594	2.478e-07	***
3	0.11222228	-0.01265823	0.00158181	3.1399	0.00169	**
4	0.04612056	-0.01265823	0.00121587	1.6857	0.09186	.
5	-0.00080356	-0.01265823	0.00109872	0.3576	0.72061	

Correlograma espacial

Prix Paris: corrélogramme spatial

