

DATOS en una RED

Parte 2 : Modelos en una red

Marzo 2019

Modelos en una red: Definiciones

S : red discreta regular (i.e. \mathbb{Z}^d)

$Z = \{Z_s, s \in S\}$, colección de v.a. reales indexadas por S .

Definición

$Z = \{Z_s, s \in \mathbb{Z}^d\}$ es un proceso real de segundo orden, estacionario si tiene una media constante y una función de covarianza invariante por traslación i.e.

- $\forall s E(Z_s) = m$
- $\forall (s, t) C(s, t) = \text{Cov}(Z_s, Z_t) = c(t - s)$

c es la función de covarianza de Z .

Modelos en una red: Definiciones

Propiedad

A cada funcion de covarianza estacionaria c en \mathbb{Z}^d se asocia una medida $F \geq 0$ y acotada

$$c(h) = \int_{\mathbb{T}^d} e^{i\langle h; u \rangle} F(du)$$

Definicion

Si $\sum_{h \in \mathbb{Z}^d} c(h)^2 < \infty$, F admite una densidad f (la densidad espectral de Z)

$$f(u) = \frac{1}{(2\pi)^d} \sum_{h \in \mathbb{Z}^d} c(h) e^{-i\langle h; u \rangle}$$

Ejemplos

- ruido blanco fuerte
- ruido blanco debil

Modelos MA

Definición

$(c_s)_{s \in \mathbb{Z}^d}$ una secuencia que verifica $\sum_s c_s^2 < \infty$ y $(\varepsilon_s)_{s \in \mathbb{Z}^d}$ un ruido blanco débil en \mathbb{Z}^d , de varianza σ_ε^2 . El modelo

$$Z_s = \sum_{t \in \mathbb{Z}^d} c_t \varepsilon_{s-t}$$

define un proceso estacionario $MA(\infty)$ (Moving Average).

Propiedad

La covarianza de un proceso $MA(\infty)$ en \mathbb{Z}^d es igual a

$$c(h) = \sigma_\varepsilon^2 \sum_{t \in \mathbb{Z}^d} c_t c_{t+h}$$

su densidad espectral es

$$f(u) = \frac{\sigma_\varepsilon^2}{(2\pi)^d} \left| \sum_{t \in \mathbb{Z}^d} c_t e^{i \langle t; u \rangle} \right|^2$$

Modelo ARMA

Definición

ε un ruido blanco, P y Q dos polinomios de la variable $z \in \mathbb{C}^d$, que verifican : si $|z| = 1$, $P(z) \neq 0$, $Q(z) \neq 0$,

$$P(z) = \sum_R a_s z^s \quad a_0 = 1 \quad ; \quad Q(z) = \sum_S b_s z^s \quad b_0 = 1$$

R, S , partes finitas de $\mathbb{Z}^d \ni 0$ la ecuacion

$$P(B)Z_s = Q(B)\varepsilon_s \quad (B \text{ operador retraso})$$

admite una solución estacionaria Z en L^2 . Z es un proceso ARMA.

Propiedad

La densidad espectral de un proceso ARMA en \mathbb{Z}^d es

$$f(u) = \frac{\sigma^2}{(2\pi)^d} \left| \frac{Q}{P}(e^{iu}) \right|^2$$

Modelo SAR (Simultaneous AR)

Definicion

$R \subset \mathbb{Z}^d$ finita que no contiene $\{0\}$, $a = \{a_s, s \in R\}$, $(\varepsilon_s)_{s \in \mathbb{Z}^d}$ un ruido blanco debil en \mathbb{Z}^d . El modelo

$$Z_s = \sum_{t \in R} a_t Z_{s-t} + \varepsilon_s$$

define un proceso estacionario SAR (Simultaneous AR).

Ejemplo Modelo 4 vecinos mas cercanos

$$Z_{s_1, s_2} = \alpha(Z_{s_1-1, s_2} + Z_{s_1+1, s_2} + Z_{s_1, s_2-1} + Z_{s_1, s_2+1}) + \varepsilon_{s_1, s_2}$$

Comentarios Este modelo es

- no causal
- no identifiable
- la estimacion por MCO no es consistente

Modelo CAR (Conditional AR)

Definicion

$L \subset \mathbb{Z}^d$ una parte finita simetrica que no contiene $\{0\}$,

$c = \{c_s, s \in L, c_s = c_{-s}\}$, el modelo

$$Z_s = \sum_{t \in L} c_t Z_{s-t} + e_s \quad E(e_s) = 0 \quad \text{cov}(e_s, Z_t) = 0 \text{ si } s \neq t$$

define un proceso estacionario CAR (Conditional AR).

Comentarios

- Z es L-markoviano, $\sum_{t \in L} c_t Z_{s-t}$ es la mejor prediccion lineal de Z_s dadas las otras variables.
- Los residuos e_s no forman un ruido blanco, son correlacionados.
- Los modelos CAR son identificables.
- La estimacion por MCO es consistente.

Modelo CAR (Conditional AR)

Propiedad

Si el polinomio $P(u) = (1 - 2 \sum_{t \in L^+} c_s \cos(\langle t; u \rangle))$ no se cancela para $\|u\| = 1$, el CAR(L) es bien definido. Su densidad espectral es igual a

$$f(u) = \frac{\sigma_e^2}{(2\pi)^d P(e^{iu})}$$

y la covarianza de los residuos condicionales es

$$\text{cov}(e_s, e_{s+t}) = \begin{cases} \sigma_e^2 & \text{si } t = 0 \\ -\sigma_e^2 c_t & \text{si } t \in L \\ 0 & \text{sino} \end{cases}$$

Propiedad

- Cada modelo SAR es un modelo CAR.
- En \mathbb{Z} los dos modelos coinciden.
- Si $d \geq 2$ la familia de los CAR es estrictamente mas grande

Modelos no estacionarios en una red finita

$S = \{s_1, s_2, \dots, s_n\}$, $Z = (Z_1, \dots, Z_n)$ proceso real en S .

$\varepsilon = (\varepsilon_1, \dots, \varepsilon_n)$ proceso real centrado de cuadrado integrable en S .

Modelos

$$\text{MA} : Z_s = \sum_{t \in S} b_{s,t} \varepsilon_t \quad Z = B\varepsilon$$

$$\text{AR} : Z_s = \sum_{\substack{t \in S \\ s \neq t}} a_{s,t} Z_t + \varepsilon_s \quad (I - A)Z = \varepsilon$$

$$\text{ARMA} : Z_s = \sum_{\substack{t \in S \\ s \neq t}} a_{s,t} Z_t + \sum_{t \in S} b_{s,t} \varepsilon_t \quad (I - A)Z = B\varepsilon$$

$$\Gamma = \text{cov}(\varepsilon) \quad \Sigma = \text{cov}(Z)$$

$$\text{MA} : \Sigma = B\Gamma B^t$$

$$\text{AR} : \Sigma = (I - A)^{-1} \Gamma (I - A)^{-t}$$

$$\text{ARMA} : \Sigma = (I - A)^{-1} B\Gamma B^t (I - A)^{-t}$$

Comentario ε ruido blanco, si Z es un proceso centrado, de varianza Σ inversible, entonces Z admite una representacion AR causal relativa a ε .

Modelos CAR

Representación markoviana CAR

$$Z_s = \sum_{\substack{t \in S \\ s \neq t}} c_{s,t} Z_t + e_s \quad \text{Var}(e_s) = \sigma_s^2 \quad \text{cov}(e_s, Z_t) = 0 \quad s \neq t$$
$$C_{s,t} = \begin{cases} c_{s,t} & \text{si } t \neq s \\ 0 & \text{si } t = s \end{cases}, \quad D = \text{diag}(\sigma_s^2)$$

$$\Sigma = (I - C)^{-1} D$$

restricciones : $\Sigma = (I - C)^{-1} D$ simétrica definida positiva

Ejemplo $Z \sim \mathcal{N}(\mu, \Sigma)$ en S dotado de un grafo \mathcal{G} simétrico sin bucle. Z es un campo \mathcal{G} -markoviano si $Q = \Sigma^{-1}$ verifica $q_{st} = 0$ salvo si $s \mathcal{R} t$. Entonces $Z_s/Z_t, t \neq s$ sigue el modelo CAR

$$E(Z_s | Z_t) = \mu_s - \frac{1}{q_{ss}} \sum_{s \mathcal{R} t} q_{st} (Z_t - \mu_t)$$

Modelos con vecindades

W una matriz de vecindad en S

SAR :

$$Z_s = \rho \sum_{\substack{t \in S \\ s \neq t}} w_{s,t} Z_t + \varepsilon_s \quad \text{o} \quad Z = \rho W Z + \varepsilon$$

bien definido en cuanto $(I - \rho W)$ es inversible

CAR :

$$Z_s = \rho \sum_{\substack{t \in S \\ s \neq t}} w_{s,t} Z_t + e_s \quad \text{Var}(e_s) = \sigma_s^2 \quad \text{cov}(e_s, Z_t) = 0 \quad s \neq t$$

$(I - \rho W)$ inversible, simétrica definida positiva.

Campos de Gibbs-Markov

S : conjunto discreto de nodos (lugares)

$Z = (Z_i, i \in S)$ con valores en E^S , E espacio de estado general

Objetivo describir el campo Z con sus distribuciones condicionales.

Restricciones las distribuciones condicionales necesitan definir una distribución conjunta única

Campos de Gibbs-Markov

Proposición

Φ una familia de funciones definida en un conjunto \mathcal{A} de partes de S que verifica

1.

$$U_{\Lambda}^{\Phi}(z) = \sum_{\substack{A \in \mathcal{A} \\ A \cap \Lambda \neq \emptyset}} \phi_A(z) \text{ es finita para } \Lambda \subset S$$

2.

$$\int_{E^{\Lambda}} \exp U_{\Lambda}^{\Phi}(z_{\Lambda}, z^{\Lambda}) dz_{\Lambda} < +\infty$$

Entonces la familia de distribuciones condicionales $\{\pi_{\Lambda}^{\Phi}(\cdot | z^{\Lambda})\}$ de densidad

$$\{\pi_{\Lambda}^{\Phi}(z_{\Lambda} | z^{\Lambda})\} = \left(\int_{E^{\Lambda}} \exp U_{\Lambda}^{\Phi}(z_{\Lambda}, z^{\Lambda}) dz_{\Lambda} \right)^{-1} \exp U_{\Lambda}^{\Phi}(z)$$

es coherente.

Ejemplo: modelo de Ising

Definición

Z un campo definido en S , de distribuciones condicionales $\{\pi_{\Lambda}^{\Phi}(z_{\Lambda}|z^{\Lambda})\}$. Z es un campo de Gibbs de potencial Φ y de energía U^{Φ} .

Modelo de Ising : modelo isotropico con 4-vecinos mas cercanos
 $S \subset \mathbb{Z}^2$, $E = \{-1, +1\}$, $\mathcal{A} = \{\text{conjuntos unitarios, vecinos}\}$

$$\phi_{\{i\}}(z) = \alpha z_i \quad \phi_{\{i,j\}}(z) = \beta z_i z_j \text{ si } \|i - j\|_1 = 1$$

Energía

$$U_{\Lambda}(z_{\Lambda}, z^{\Lambda}) = \alpha \sum_{i \in \Lambda} z_i + \beta \sum_{\substack{i \in \Lambda \\ j \text{ vecino } i}} z_i z_j$$

distribucion condicional


$$\pi_{\Lambda}(z_{\Lambda}|z^{\Lambda}) = \left(\sum_{z_{\Lambda} \in E^{\Lambda}} \exp U_{\Lambda}(z_{\Lambda}, z^{\Lambda}) \right)^{-1} \exp U_{\Lambda}(z_{\Lambda}, z^{\Lambda})$$

Ejemplo : modelo de Ising


$\beta = 0$



$\beta = 100$



$\beta = -100$



Ejemplo : modelo de Potts

Generalización del modelo de Ising con $E = \{a_0, a_1, \dots, a_{K-1}\}$

$$\begin{aligned}\phi_{\{i\}}(z) &= \alpha_k && \text{si } z_i = a_k \\ \phi_{\{i,j\}}(z) &= \beta_{kl} && \text{si } \{z_i, z_j\} = \{a_k, a_l\} \text{ } i,j, \text{ vecinos}\end{aligned}$$

Energía


$$U_{\Lambda}(z) = \sum_k \alpha_k n_k + \sum_{k < l} \beta_{kl} n_{kl}$$

n_k número de nodos con valor a_k en Λ


n_{kl} número de nodos vecinos con valor $\{a_k, a_l\}$ en Λ

Ejemplo : modelo de Potts


$\beta=0$



$\beta=0.5$



$\beta=1.2$



Campo de Markov

Definicion

- Z es un campo de Markov en S para el grafo \mathcal{G} si la distribucion de Z en Λ condicional a z^Λ solo depende de su frontera

$$\pi_\Lambda(z_\Lambda | z^\Lambda) = \pi_\Lambda(z_\Lambda | z_{\partial\Lambda})$$

- Una parte de S es un clique del grafo \mathcal{G} si es un conjunto unitario o si sus elementos son vecinos de dos en dos en \mathcal{G} .

Teorema (Hammersley-Clifford)

π la distribucion de un campo de Markov que verifica $\pi_\Lambda(z_\Lambda | z^\Lambda) > 0$. Entonces existe una familia Φ definida en los cliques de \mathcal{G} que verifica : π es la distribucion de un campo de Gibbs de potencial Φ .

Si \mathcal{C} es una familia que contiene todos los conjuntos unitarios, entonces un campo de Gibbs de potenciales definidos en \mathcal{C} es un campo de Markov para el grafo de vecindad \mathcal{C} .

Auto-modelos markovianos

Teorema

Una familia de distribuciones condicionales $\pi(\cdot|z^i)$ de un campo de Markov de distribución π , que pertenecen a la familia exponencial

$$\log \pi(z_i|z^i) = A_i(z^i)B_i(z_i) + C_i(z_i) + D(z^i)$$

entonces existe α_i y $\beta_{ij} = \beta_{ji}$ que verifican

$$A_i(z^i) = \alpha_i + \sum_{j \neq i} \beta_{ij} B_j(z_j)$$

y

$$\phi_i(z_i) = \alpha_i B_i(z_i) + C_i(z_i) \quad \phi_{ij}(z_i, z_j) = \beta_{ij} B_i(z_i) B_j(z_j)$$

A la inversa, las distribuciones condicionales exponenciales que verifican $A_i(z^i) = \alpha_i + \sum_{j \neq i} \beta_{ij} B_j(z_j)$ se reúnen en una distribución junta que es un campo de Markov de potencial la familia $\Phi = \{\phi_i, \phi_{ij}\}$.

Si $\phi_{ij} = z_i z_j$, y $\beta_{ij} = \beta_{ji}$ entonces Z de distribución π es un auto-modelo markoviano.

Auto-modelos markovianos

Ejemplos:

1. Auto-logística $E = \{0, 1\}$

$$U(z) = \sum_i \alpha_i z_i + \sum_{i \text{ vecino } j} \beta_{ij} z_i z_j$$

2. Poissoniano $E = \mathbb{N}$

$$U(z) = \sum_i (\alpha_i z_i + \log(z_i!)) + \sum_{i \text{ vecino } j} \beta_{ij} z_i z_j$$

3. Exponencial $E = \mathbb{R}$

$$U(z) = - \sum_i \alpha_i z_i - \sum_{i \text{ vecino } j} \beta_{ij} z_i z_j$$

4. Gaussiano $E = \mathbb{R}$

$$U(z) = -(1/2)^t (x - \mu) Q (x - \mu)$$

$Q = \Sigma^{-1}$ matriz de precision.

Estimacion de los parametros

Maxima de verosimilitud

$$Z \sim \mathcal{N}(0, \Sigma(\theta))$$

$$\log L_n(\theta) = -\frac{1}{2} \log |\Sigma(\theta)| \sigma^2 + \frac{1}{2} Z^t \Sigma(\theta)^{-1} Z$$

$$\text{SAR} : Z^t \Sigma(\theta)^{-1} Z = \sigma_\varepsilon^{-2} \|(I - A(\theta))Z\|^2$$

$$\hat{\sigma}_\varepsilon^2 = \frac{1}{n} \|(I - A(\theta))Z\|^2$$

$$\hat{\theta} \text{ minimiza } -\frac{2}{n} \log |I - A(\theta)| + \log(\sigma_\varepsilon^2(\theta))$$

$$\text{CAR} : Z^t \Sigma(\theta)^{-1} Z = \sigma_e^{-2} Z^t (I - C(\theta)) Z$$

$$\hat{\sigma}_e^2 = \frac{1}{n} Z^t (I - C(\theta)) Z$$

$$\hat{\theta} \text{ minimiza } -\frac{2}{n} \log |I - C(\theta)| + \log(\sigma_e^2(\theta))$$

Estimacion de los parametros

Campo de Markov

- estimacion por maxima verosimilitud consistente bajo ciertas restricciones
 - distribuciones condicionales invariantes por translacion
 - potenciales medibles y acotados
 - dificultad para calcular la constante de normalizacion
- Pseudo verosimilitud condicional

$$l^{PVC}(\theta) = \sum_i \log \pi_i(z_i | z_{\partial i}, \theta) \quad \hat{\theta}^{PVC} = \operatorname{argmax}_{\theta} l^{PVC}(\theta)$$

- buena eficacia si correlacion espacial moderada,
- no se necesita el calculo de la constante de normalizacion.

Regresion espacial

X variables explicativas.

Modelo lineal estandar

$$Z_s = \beta_0 + \sum_{i=1}^k \beta_i X_{is} + \varepsilon_s \quad \varepsilon \sim \mathcal{N}(0, \sigma^2) \quad \text{cov}(\varepsilon) = \sigma^2 I$$

Estimacion

$$\hat{\beta} = (X^t X)^{-1} X^t Y \quad \mathbf{E}(\hat{\beta}) = \beta \quad \text{Var}(\hat{\beta}) = \sigma^2 (X X^t)^{-1}$$

$$\hat{\varepsilon} = Y - X \hat{\beta} \quad \hat{\sigma}^2 = \frac{1}{n - k - 1} \sum_i \hat{\varepsilon}_i^2$$

Si $\text{cov}(\varepsilon) = \sigma^2 A$

$$\mathbf{E}(\hat{\beta}) = \beta \quad \text{Var}(\hat{\beta}) = \sigma^2 (X X^t)^{-1} X^t A X (X X^t)^{-1}$$

$$\mathbf{E}(\hat{\sigma}^2) = \sigma^2 \frac{1}{n - k - 1} [\text{tr}(A) - \text{tr}[(X^t X)^{-1} X^t A X]] \neq \sigma^2$$

Consecuencia pruebas de Student y Fisher son falsas.

Regresion espacial

$$Z_s = \beta_0 + \sum_{i=1}^k \beta_i X_{is} + \varepsilon_s$$

- Modelos para ε
 - SAR $\varepsilon_i = \rho \sum_j w_{ij} \varepsilon_j + \eta_i \quad \eta_i \sim \mathcal{N}(0, \sigma^2)$
 - CAR $E(\varepsilon_i / \varepsilon_j) = \rho \sum_j w_{ij} \varepsilon_j \quad \text{Var}(\varepsilon_i / \varepsilon_j) = \sigma^2$
- Modelos para $\text{Var}(\varepsilon) = \sigma^2 A$
 - Modelo disco
 - si $d(i, j) < 2c \quad A_{ij} = \frac{2}{\pi} \left(\arccos\left(\frac{d(i, j)}{2c}\right) - \frac{d(i, j)}{2c} \sqrt{1 - \frac{d^2(i, j)}{4c^2}} \right)$
 - si $d(i, j) > 2c \quad A_{ij} = 0$
 - Modelo exponencial
 - Si $d(i, j) \neq 0 \quad A_{ij} = c_1 e^{-c_2 d(i, j)}, \quad A_{ii} = 1$

Regresion espacial

Estimacion


1. estimar β con MCO
2. calcular los residuos $\hat{\varepsilon} = Z - X\hat{\beta}$
3. prueba de la autocorrelacion de los residuos
4. si positivo estimacion de los parametros de dependencia (MCO ou MV)

Eleccion del modelo


- Criterios tipo AIC
- Pruebas basadas en la verosimilitud (modelos encajados)
- Validacion cruzada

Regresion espacial

Paris: prix des logements au m2 (2009)




Paris: population (1000h)



Explica la poblacion los precios ?

Regression espacial

Residus modele lineaire, I = 0.17



$$Y = X\beta + \varepsilon$$

Modelo lineal

Coefficients:

| | Estimate | Std. Error | t value | Pr(> t) |
|-------------|------------|------------|---------|--------------|
| (Intercept) | 8.137e+03 | 2.547e+02 | 31.950 | < 2e-16 *** |
| popu | -4.374e-02 | 7.397e-03 | -5.913 | 8.42e-08 *** |

Residual standard error: 1378 on 78 degrees of freedom

Multiple R-squared: 0.3095, Adjusted R-squared: 0.3006

F-statistic: 34.96 on 1 and 78 DF, p-value: 8.417e-08


Moran I statistic standard deviate = 2.855, p-value = 0.002152

sample estimates:

| Moran I statistic | Expectation | Variance |
|-------------------|--------------|-------------|
| 0.172829269 | -0.012658228 | 0.004221085 |

Modelo Lineal General

Residus modele lineaire généralisé, $I = 0.26$



$$Y = X\beta + \varepsilon \quad \text{cov}(\varepsilon_s, \varepsilon_{s+h}) = ce^{-|h|/a}$$

Modelo Lineal General

AIC BIC logLik
1377.579 1389.362 -683.7893

Correlation Structure: Exponential spatial correlation

Parameter estimate(s):

| range | nugget |
|--------------|--------------|
| 2.991497e+01 | 5.254981e-08 |

Coefficients:

| | Value | Std.Error | t-value | p-value |
|-------------|----------|-----------|-----------|---------|
| (Intercept) | 7602.034 | 381.6749 | 19.917560 | 0.000 |
| popu | -0.028 | 0.0082 | -3.405607 | 0.001 |

Residual standard error: 1457.662


Moran I statistic standard deviate = 4.2642, p-value = 1.003e-05

sample estimates:

| Moran I statistic | Expectation | Variance |
|-------------------|--------------|-------------|
| 0.263173949 | -0.012658228 | 0.004184189 |

Modelo con errores SAR

Residuos modelo SAR sur les erreurs, $\lambda = 0.03$



$$Y = X\beta + \varepsilon \quad \varepsilon = \lambda W\varepsilon + \eta$$

Modelo con errores SAR

Coefficients: (asymptotic standard errors)

| | Estimate | Std. Error | z value | Pr(> z) |
|-------------|-------------|------------|---------|-----------|
| (Intercept) | 7.7114e+03 | 3.8817e+02 | 19.8658 | < 2.2e-16 |
| popu | -2.8557e-02 | 8.4861e-03 | -3.3651 | 0.0007651 |

Lambda: 0.55716, LR test value: 8.9876, p-value: 0.0027181

Log likelihood: -686.2933 for error model

ML residual variance (sigma squared): 1543100, (sigma: 1242.2)

AIC: 1380.6, (AIC for lm: 1387.6)

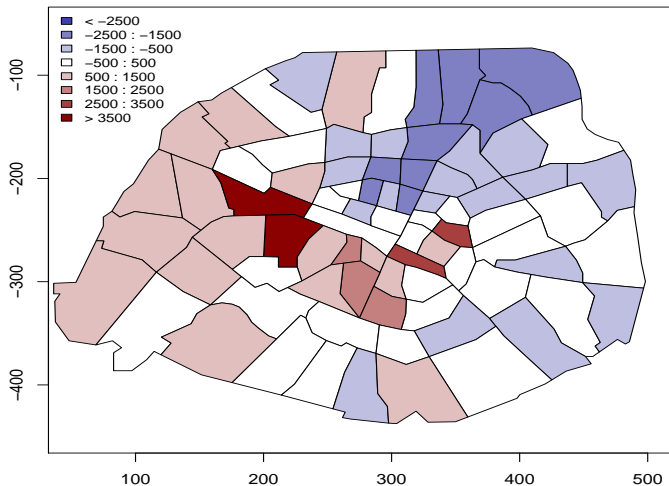
Moran I statistic standard deviate = 0.6913, p-value = 0.2447

sample estimates:

| Moran I statistic | Expectation | Variance |
|-------------------|--------------|-------------|
| 0.031895387 | -0.012658228 | 0.004153078 |

Modelo con retrasos SAR

Residuos modelo SAR à retard, I = 0.05



$$Y = \rho WY + X\beta + \varepsilon$$

Modelo con retrasos SAR

Coefficients: (numerical Hessian approximate standard errors)

| | Estimate | Std. Error | z value | Pr(> z) |
|-------------|-------------|------------|---------|-----------|
| (Intercept) | 5389.732779 | 905.044418 | 5.9552 | 2.597e-09 |
| popu | -0.032487 | 0.007707 | -4.2152 | 2.496e-05 |

Rho: 0.35137, LR test value: 8.8233, p-value: 0.0029741

Log likelihood: -686.3755 for lag model

ML residual variance (sigma squared): 1617400, (sigma: 1271.8)

AIC: 1380.8, (AIC for lm: 1387.6)


Moran I statistic standard deviate = 0.9095, p-value = 0.1816

sample estimates:

| Moran I statistic | Expectation | Variance |
|-------------------|--------------|-------------|
| 0.046236758 | -0.012658228 | 0.004193694 |

Modelo con retrasos en los errores y las covariables

Residuos modelo SAR mixte, I = 0.04



$$Y = \rho_1 WY + X\beta + \rho_2 WX\beta + \varepsilon \quad \varepsilon = \lambda W\varepsilon + \eta$$

Modelo con retrasos en los errores y las covariables

Coefficients: (numerical Hessian approximate standard errors)

| | Estimate | Std. Error | z value | Pr(> z) |
|-----------------|-------------|------------|---------|-----------|
| (Intercept) | 7.3754e+03 | 1.3556e+03 | 5.4408 | 5.305e-08 |
| popu | -2.3686e-02 | 8.8749e-03 | -2.6688 | 0.007612 |
| lag.(Intercept) | -2.5480e+03 | 1.9173e+03 | -1.3289 | 0.183874 |
| lag.popu | -1.1588e-02 | 1.4143e-02 | -0.8193 | 0.412600 |

Rho: 0.4434, LR test value: 6.5523, p-value: 0.010475

Log likelihood: -684.0203 for mixed model

ML residual variance (sigma squared): 1499800, (sigma: 1224.7)

AIC: 1380, (AIC for lm: 1384.6)

Moran I statistic standard deviate = 0.7665, p-value = 0.2217

sample estimates:

| Moran I statistic | Expectation | Variance |
|-------------------|--------------|-------------|
| 0.036897881 | -0.012658228 | 0.004180066 |

Comparacion de los modelos

| | Model | df | AIC | logLik | Test | L.Ratio | p-value |
|-------------------|-------|----|--------|---------|------|---------|----------|
| prixm2.mixte | 1 | 6 | 1380.0 | -684.02 | 1 | | |
| prixm2.errorsarlm | 2 | 4 | 1380.6 | -686.29 | 2 | 4.5460 | 0.103002 |
| prixm2.lm | 3 | 3 | 1387.6 | -690.79 | 3 | 8.9876 | 0.002718 |

| | Model | df | AIC | logLik | Test | L.Ratio | p-value |
|-----------------|-------|----|--------|---------|------|---------|----------|
| prixm2.mixte | 1 | 6 | 1380.0 | -684.02 | 1 | | |
| prixm2.lagsarlm | 2 | 4 | 1380.8 | -686.38 | 2 | 4.7103 | 0.094878 |
| prixm2.lm | 3 | 3 | 1387.6 | -690.79 | 3 | 8.8233 | 0.002974 |