



7º CONGRESO FORESTAL ESPAÑOL

**Gestión del monte: servicios
ambientales y bioeconomía**

26 - 30 junio 2017 | Plasencia
Cáceres, Extremadura

7CFE01-416

Edita: Sociedad Española de Ciencias Forestales
Plasencia. Cáceres, Extremadura. 26-30 junio 2017
ISBN 978-84-941695-2-6

© Sociedad Española de Ciencias Forestales

Aplicación del modelo de Poisson mixto con efectos espaciales para la predicción de incendios en Galicia

BOUBETA, M.¹, LOMBARDÍA, M. J.¹, MORALES, D.² Y MAREY-PÉREZ, M.^{3, 4}

¹ MODES, Grupo de Modelización, Optimización e Inferencia Estadística, Universidade da Coruña.

² CIO, Centro de Investigación Operativa, Universidad Miguel Hernández de Elche.

³ Instituto de Estudos e Desenvolvimento de Galicia.

⁴ GI-1716 PROEPLA, Proxectos e Planificación. Universidade de Santiago de Compostela. Manuel.marey@udc.es

Resumen

Los incendios forestales suponen la principal amenaza para la actividad forestal en el sur de Europa. Una de las regiones con mayor actividad incendiaria es Galicia. Dada su importancia y repercusión, se han llevado a cabo multitud de enfoques y análisis. Para estudiar la variable número de incendios, este trabajo aplica un modelo de Poisson mixto con efecto de área y correlación espacial SAR(1). El comportamiento del estimador plug-in del número medio de incendios por área forestal, obtenido bajo este modelo, es analizado y comparado frente a las correspondientes versiones obtenidas bajo los modelos de Poisson de efectos fijos y de efectos aleatorios independientes. Como medida de precisión del estimador propuesto se propone un MSE bootstrap. Finalmente, la metodología desarrollada se aplica al conjunto de datos de incendios forestales en Galicia. Se aplica el test de Moran sobre los residuos del modelo de efectos fijos para estudiar la existencia de una estructura de correlación espacial subyacente. En el análisis se observa una mejora de la precisión de las estimaciones cuando se considera el modelo más complejo incluyendo efectos aleatorios SAR(1), dado que es capaz de captar parte de la variabilidad no explicada por sus competidores.

Palabras clave

Correlación SAR(1), estimador plug-in, MSE bootstrap, test de Moran.

1. Introducción

Galicia es una de las comunidades autónomas con mayor densidad de incendios y superficie quemada de Europa (ALVAREZ-DÍAZ et al, 2015). Desde el año 1999, la estructura administrativa del sistema de lucha contra incendios ha sido dividida en cuatro niveles: regional, provincial (4), distritos forestales (19) y áreas forestales (63). En Agosto de 2006, un total de 83000 hectáreas (7,5% del territorio), se ha visto afectado en las provincias de A Coruña y Pontevedra por los incendios forestales (GONZÁLEZ-ALONSO & MERINO-DE-MIGUEL, 2009; RIOS-PENA et al, 2017). Este año ha supuesto un periodo de crisis en la región por los incendios forestales que afectaron a la comunidad (FERNANDES, 2008; BOUBETA et al 2015; BOUBETA et al 2016).

En este trabajo se analiza y modeliza el número de incendios por área forestal en la comunidad autónoma de Galicia durante verano del 2008. La metodología propuesta usa los modelos de Poisson, los cuales son usados para analizar conteos, y los modelos mixtos que introducen términos extra, denominados efectos aleatorios, que capturan la variabilidad entre áreas. Este modelo es un caso particular de los modelos mixtos generalizados (GLMM). Se puede ver más información sobre estos modelos en DEMIDENKO (2004) y MCCULLOCH et al (2008), entre otros. Diferentes estudios han introducido los modelos de Poisson para la predicción del número de incendios en los últimos años. Por ejemplo, MANDALLAZ & YE (1997) presentaron una metodología estadística general para la predicción del número de incendios en Francia, Italia, Portugal y Suiza. WOTTOM et al (2003) desarrollaron modelos predictivos de Poisson para el número diario de incendios en eco-regiones de Ontario. Sin embargo, el uso de modelos de Poisson mixtos en este contexto es relativamente nuevo, dando buenos resultados como se ha mostrado en BOUBETA et al (2015).

En este trabajo se deriva el estimador plug-in basado en el modelo de Poisson mixto con efectos de área correlados espacialmente según un proceso SAR(1). Este modelo generaliza al estudiado en BOUBETA et al (2015), introduciendo correlación espacial. Se considera el error cuadrático medio (MSE) como medida de precisión del estimador plug-in propuesto y se ofrece un procedimiento bootstrap basado en el de GONZÁLEZ-MANTEIGA et al (2007) y GONZÁLEZ-MANTEIGA et al (2008a) en el contexto de los modelos mixtos normal y logístico, y extendido posteriormente por GONZÁLEZ-MANTEIGA et al (2008b) al contexto multivariante.

2. Objetivos

El objetivo principal del presente trabajo es explicar y modelar el número de incendios en Galicia durante el verano de 2008 por áreas. Para ello se proporciona un modelo de Poisson mixto con correlación espacial. Bajo este modelo se obtiene el estimador del método de los momentos (MM) de los parámetros del modelo y se aporta un estimador plug-in, donde los efectos aleatorios son predichos mediante su empírico best predictor (EBP).

3. Metodología

El modelo mixto de Poisson con efectos espaciales SAR(1) extiende el modelo mixto de Poisson con efectos aleatorios independientes propuesto en BOUBETA et al (2015). Supongamos que la región bajo estudio puede ser particionada en D áreas o dominios y denotemos cada dominio particular por d ($d = 1, \dots, D$). Sea $\mathbf{v} = (v_1, \dots, v_D)'$ un vector de efectos aleatorios correlados espacialmente según un proceso SAR(1) con parámetro de autorregresión desconocido ρ y matriz de proximidad conocida \mathbf{W} . Esto significa que el vector de efectos aleatorios \mathbf{v} se expresa mediante la combinación lineal

$$\mathbf{v} = \rho \mathbf{W} \mathbf{v} + \mathbf{u},$$

donde $\mathbf{u} \sim N(\mathbf{0}, \mathbf{I}_D)$, $\mathbf{0}$ es el D -vector de ceros y \mathbf{I}_D denota la matriz identidad de orden D . Suponiendo que la matriz $(\mathbf{I}_D - \rho \mathbf{W})$ es no singular, el vector de efectos aleatorios \mathbf{v} puede ser expresado como $\mathbf{v} = (\mathbf{I}_D - \rho \mathbf{W})^{-1} \mathbf{u}$.

Para la matriz de proximidad \mathbf{W} , se supone que es obtenida a partir de una matriz de proximidad original \mathbf{W}^0 , cuyos elementos diagonales son cero y los restantes elementos son 1 cuando los dominios correspondientes son vecinos y cero en otro caso. Se lleva a cabo una estandarización por filas dividiendo cada entrada de la matriz \mathbf{W}^0 por la suma de elementos de la fila. Por lo tanto, \mathbf{W} es estocástica por filas. Entonces, el parámetro de autorregresión ρ es una correlación y se denomina parámetro de autocorrelación espacial. La ecuación anterior implica que $\mathbf{v} \sim N(\mathbf{0}, \mathbf{\Gamma}(\rho))$, donde $\mathbf{\Gamma}(\rho) = \mathbf{C}^{-1}(\rho)$ y $\mathbf{C}(\rho) = (\mathbf{I}_D - \rho \mathbf{W})' (\mathbf{I}_D - \rho \mathbf{W})$. Por lo tanto, la función de densidad de los efectos aleatorios es

$$f(\mathbf{v}) = (2\pi)^{-D/2} |\mathbf{\Gamma}(\rho)|^{-1/2} \exp \left\{ -\frac{1}{2} \mathbf{v}' \mathbf{\Gamma}^{-1}(\rho) \mathbf{v} \right\}.$$

Diremos que el vector de variables respuestas $\mathbf{y} = (y_1, \dots, y_D)'$ sigue un modelo de Poisson mixto con efectos aleatorios \mathbf{v} , correlados espacialmente según un proceso SAR(1), si la distribución condicionada de y_d , dado v_d , es

$$y_d | v_d \sim \text{Poiss}(\mu_d), \quad d = 1, \dots, D,$$

donde μ_d denota la media de la distribución de Poisson. Además suponemos que los y_d 's son independientes condicionados a \mathbf{v} y que el parámetro natural, $\log(\mu_d)$, puede ser expresado en términos de un conjunto de p variables auxiliares o covariables $\mathbf{x}_d = (x_{d1}, \dots, x_{dp})$, a través de un modelo de regresión, es decir

$$\text{Modelo S1: } \log(\mu_d) = \mathbf{x}_d \boldsymbol{\beta} + \phi v_d, \quad d = 1, \dots, D, \quad (3.1)$$

donde $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)'$ y ϕ son los parámetros de los efectos fijos y de la varianza, respectivamente.

Para ajustar los parámetros del modelo $\boldsymbol{\theta} = (\beta_1, \dots, \beta_p, \phi, \rho)$, hemos obtenido el estimador del método de los momentos (MM) bajo el modelo de correlación espacial. Un conjunto natural de ecuaciones para aplicar el algoritmo MM es

$$0 = f_k(\boldsymbol{\theta}) = M_k(\boldsymbol{\theta}) - \widehat{M}_k = \frac{1}{D} \sum_{d=1}^D \exp\left\{\mathbf{x}_d \boldsymbol{\beta} + \frac{1}{2} \phi^2 \Gamma_{dd}\right\} x_{dk} - \frac{1}{D} \sum_{d=1}^D y_d x_{dk}, \quad k = 1, \dots, p,$$

$$0 = f_{p+1}(\boldsymbol{\theta}) = M_{p+1}(\boldsymbol{\theta}) - \widehat{M}_{p+1} = \frac{1}{D} \sum_{d=1}^D \left\{ \exp\left\{\mathbf{x}_d \boldsymbol{\beta} + \frac{1}{2} \phi^2 \Gamma_{dd}\right\} + \exp\{2\mathbf{x}_d \boldsymbol{\beta} + 2\phi^2 \Gamma_{dd}\} \right\} - \frac{1}{D} \sum_{d=1}^D y_d^2,$$

$$0 = f_{p+2}(\boldsymbol{\theta}) = M_{p+2}(\boldsymbol{\theta}) - \widehat{M}_{p+2} \\ = \frac{1}{D(D-1)} \sum_{d_1 \neq d_2} \exp\left\{(\mathbf{x}_{d_1} + \mathbf{x}_{d_2}) \boldsymbol{\beta} + \frac{1}{2} \phi^2 (\Gamma_{d_1 d_1} + \Gamma_{d_2 d_2} + 2\Gamma_{d_1 d_2})\right\} \\ - \frac{1}{D(D-1)} \sum_{d_1 \neq d_2} y_{d_1} y_{d_2},$$

donde $d_1, d_2 = 1, \dots, D$. El estimador MM de $\boldsymbol{\theta}$ viene dado como solución del sistema de ecuaciones no lineales anterior. La fórmula de actualización del algoritmo de Newton-Raphson es

$$\boldsymbol{\theta}^{(l+1)} = \boldsymbol{\theta}^{(l)} - \mathbf{H}^{-1}(\boldsymbol{\theta}^{(l)}) \mathbf{f}(\boldsymbol{\theta}^{(l)}),$$

donde $\boldsymbol{\theta} = \underset{1 \leq k \leq p+2}{col} (\theta_k)$, $\mathbf{f}(\boldsymbol{\theta}) = \underset{1 \leq k \leq p+2}{col} (f_k(\boldsymbol{\theta}))$, $\mathbf{H}(\boldsymbol{\theta}) = \left(\frac{\partial f_k(\boldsymbol{\theta})}{\partial \theta_r} \right)_{k,r=1,\dots,p+2}$.

Como semillas del algoritmo para $\boldsymbol{\beta}$ y ϕ , tomamos el estimador MM bajo el modelo mixto con efectos aleatorios independientes ($\rho = 0$). Este modelo mantiene la expresión (3.1), pero a diferencia del anterior, este asume que los efectos aleatorios son i.i.d $N(0,1)$. Respecto al parámetro de autocorrelación espacial ρ , proponemos usar la medida de Moran I de autocorrelación espacial, es decir

$$I = \frac{D}{\sum_{d_1=1}^D \sum_{d_2=1}^D w_{d_1 d_2}} \frac{\sum_{d_1=1}^D \sum_{d_2=1}^D w_{d_1 d_2} (\tilde{v}_{d_1} - \tilde{v})(\tilde{v}_{d_2} - \tilde{v})}{\sum_{d=1}^D (\tilde{v}_d - \tilde{v})^2},$$

donde \tilde{v}_d ($d = 1, \dots, D$), son los efectos aleatorios predichos bajo el modelo con $\rho = 0$, $\tilde{v} = \frac{1}{D} \sum_{d=1}^D \tilde{v}_d$ y los $w_{d_1 d_2}$'s ($d_1, d_2 = 1, \dots, D$) son los elementos de la matriz de proximidad \mathbf{W} .

Para estimar el parámetro objetivo $\mu_d = \exp\{\mathbf{x}_d \boldsymbol{\beta} + \phi v_d\}$ ($d = 1, \dots, D$), proponemos un estimador plug-in. Este viene dado por $\hat{\mu}_d = \exp\{\mathbf{x}_d \hat{\boldsymbol{\beta}} + \hat{\phi} \hat{v}_d\}$.

Dado que el estimador MM solo proporciona estimaciones de los efectos fijos $\boldsymbol{\beta}$ y de los parámetros de varianza ϕ y autocorrelación ρ , para poder calcular el estimador plug-in de μ_d , $\hat{\mu}_d$, es necesario predecir el vector de efectos aleatorios \mathbf{v} . En este trabajo proponemos predecir el vector de efectos aleatorios mediante su EBP. Este predictor se obtiene a partir del correspondiente best predictor (BP). El BP \hat{v}_d de v_d es el predictor que minimiza el error cuadrático medio en el conjunto de los predictores insesgados, y su correspondiente EBP se obtiene reemplazando el vector de parámetros teóricos del modelo, $\boldsymbol{\theta}$, por un estimador $\hat{\boldsymbol{\theta}}$ (por ejemplo el estimador MM). El BP de v_d viene dado por

$$\hat{v}_d(\boldsymbol{\theta}) = E_{\boldsymbol{\theta}}[v_d | \mathbf{y}] = \frac{\int v_d \prod_{i=1}^D P(y_i | v_i) f(\mathbf{v}) d\mathbf{v}}{\int \prod_{i=1}^D P(y_i | v_i) f(\mathbf{v}) d\mathbf{v}} = \frac{N_{v,d}(\mathbf{y}, \boldsymbol{\theta})}{D_d(\mathbf{y}, \boldsymbol{\theta})},$$

donde

$$N_{v,d}(\mathbf{y}, \boldsymbol{\theta}) = \int v_d \exp\left\{\sum_{i=1}^D [y_i(\mathbf{x}_i \boldsymbol{\beta} + \phi v_i) - \exp\{\mathbf{x}_i \boldsymbol{\beta} + \phi v_i\}]\right\} f(\mathbf{v}) d\mathbf{v},$$

$$D_d(\mathbf{y}, \boldsymbol{\theta}) = \int \exp\left\{\sum_{i=1}^D [y_i(\mathbf{x}_i \boldsymbol{\beta} + \phi v_i) - \exp\{\mathbf{x}_i \boldsymbol{\beta} + \phi v_i\}]\right\} f(\mathbf{v}) d\mathbf{v}.$$

El EBP de v_d es $\hat{v}_d(\hat{\theta})$. Las integrales involucradas en su cálculo pueden ser aproximadas mediante un algoritmo Monte Carlo antitético. Los pasos son:

1. Estimar $\hat{\theta} = (\hat{\beta}, \hat{\phi}, \hat{\rho})$.
2. Para $l = 1, \dots, L$, generar $\mathbf{v}^{(l)}$ i.i.d. $N(\mathbf{0}, \Gamma(\hat{\rho}))$ y calcular sus antitéticos $\mathbf{v}^{(L+l)} = -\mathbf{v}^{(l)}$.
3. Calcular $\hat{v}_d(\hat{\theta}) = \frac{\hat{N}_{v,d}(\mathbf{y}, \hat{\theta})}{\hat{D}_d(\mathbf{y}, \hat{\theta})}$, ($d = 1, \dots, D$), donde

$$\hat{N}_{v,d}(\mathbf{y}, \hat{\theta}) = \frac{1}{2L} \sum_{l=1}^{2L} v_d^{(l)} \exp \left\{ \sum_{i=1}^D [y_i (\mathbf{x}_i \hat{\beta} + \hat{\phi} v_i^{(l)}) - \exp \{ \mathbf{x}_i \hat{\beta} + \hat{\phi} v_i^{(l)} \}] \right\},$$

$$\hat{D}_d(\mathbf{y}, \hat{\theta}) = \frac{1}{2L} \sum_{l=1}^{2L} \exp \left\{ \sum_{i=1}^D [y_i (\mathbf{x}_i \hat{\beta} + \hat{\phi} v_i^{(l)}) - \exp \{ \mathbf{x}_i \hat{\beta} + \hat{\phi} v_i^{(l)} \}] \right\}.$$

Consideraremos el MSE bajo el modelo de Poisson mixto con efectos espaciales SAR(1) como medida de precisión del estimador propuesto. Dado que el enfoque analítico es computacionalmente exigente, proponemos estimar el MSE de $\hat{\mu}_d$ mediante el siguiente procedimiento bootstrap:

1. Ajustar el modelo a la muestra y calcular el estimador $\hat{\theta} = (\hat{\beta}, \hat{\phi}, \hat{\rho})$.
2. Para cada dominio d ($d = 1, \dots, D$), repetir B veces ($b = 1, \dots, B$):
 - i. Generar los efectos aleatorios bootstrap $\mathbf{v}^{*(b)} = (v_1^{*(b)}, \dots, v_D^{*(b)})' \sim N(\mathbf{0}, \Gamma(\hat{\rho}))$.
 - ii. Calcular el parámetro objetivo bootstrap $\mu_d^{*(b)} = \exp \{ \mathbf{x}_d \hat{\beta} + \hat{\phi} v_d^{*(b)} \}$.
 - iii. Generar las variables respuesta $y_d^{*(b)} \sim \text{Poisson}(\mu_d^{*(b)})$.
 - iv. Para cada muestra bootstrap, calcular el estimador $\hat{\theta}^{*(b)}$ y el estimador plug-in del parámetro objetivo $\hat{\mu}_d^{*(b)} = \hat{\mu}_d^{*(b)}(\hat{\theta}^{*(b)})$.

Output:

$$mse^*(\hat{\mu}_d) = \frac{1}{B} \sum_{b=1}^B (\hat{\mu}_d^{*(b)} - \mu_d^{*(b)})^2.$$

4. Resultados

El interés de este trabajo es conocer el comportamiento del número de incendios en Galicia por áreas forestales durante el verano del 2008. Las áreas forestales constituyen una división territorial que divide la comunidad en $D=63$ subregiones. Para llevar a cabo tal análisis, se usa un conjunto de datos extraído de las bases de datos paramétricas de incendios publicada por el *Ministerio de Agricultura y Pesca, Alimentación y Medio Ambiente*.

Suponemos que la variable respuesta en el dominio d ($d = 1, \dots, D$), puede ser explicada por algunas variables auxiliares a través de un modelo de regresión de Poisson con efectos de área con correlación espacial SAR(1). Concretamente, hemos utilizado: precipitación acumulada (*acumRain*), temperatura media (*averTemp*), población (*pop*), titulares catastrales (*cadHold*) y superficie forestal (*forestArea*) por área.

La Tabla 1 presenta las estimaciones de los efectos fijos (por MM) de las variables significativas (p-valor $< 0,05$) del Modelo S1. Las estimaciones sugieren que *cadHold* está relacionada directamente con la variable respuesta. Esto es, un aumento en esta variable provoca un aumento en la variable respuesta si la variable *acumRain* permanece constante. Por otro lado, la relación entre las variables respuesta y auxiliar *acumRain* es inversa, es decir, un aumento en la variable auxiliar provoca un decrecimiento en la variable respuesta si *cadHold* permanece constante. El parámetro de la varianza estimado es $\hat{\phi} = 0,351$ y el de autocorrelación espacial es $\hat{\rho} = 0,119$.

A efectos comparativos, se ha ajustado un modelo de Poisson clásico (sin efectos aleatorios) sobre la misma información auxiliar. Es decir, se ha considerado el modelo

$$\text{Modelo 0: } \log(\mu_d) = \mathbf{x}_d \boldsymbol{\beta}, \quad d = 1, \dots, D, \quad (3.2)$$

y se ha aplicado el test de Moran I de autocorrelación espacial sobre los residuos de este modelo para estudiar si es factible el uso del modelo de Poisson mixto con correlación espacial. El p-valor del

contraste es 0,0007. Por lo tanto, se rechaza la hipótesis nula de no correlación espacial a nivel $\alpha = 0,05$. En consecuencia, el uso de un modelo de mayor complejidad contemplando efectos aleatorios espaciales SAR(1) parece más adecuado.

Tabla 1. Estimaciones MM de las variables significativas del modelo de Poisson mixto con efectos SAR(1).

Coefficiente	Estimación	Std. Error	z value	Pr(> z)
Intercept	2,3911	0,0684	34,9421	<0,001
Precipitación acumulada	-0,3166	0,0774	-4,0921	<0,001
Titulares catastrales	0,3780	0,0577	6,5522	<0,001

La Figura 1 presenta los residuos de Pearson del Modelo 0 (3.2) a la izquierda y del Modelo S1 (3.1) en el centro. Se observa una importante mejora cuando uno usa un modelo de mayor complejidad incorporando efectos aleatorios espaciales SAR(1), ya que los residuos son menores. La raíz del MSE relativo (RRMSE) se muestra en la Figura 1 (derecha). El RRMSE medio obtenido es del 25,98%.




Figura 1. Residuos de Pearson del Modelo 0 (izquierda), Modelo S1 (centro) y RRMSE del estimador plug-in bajo el Modelo S1.

5. Discusión

Los incendios en la Europa Mediterránea son un problema de primera magnitud que merece análisis cada vez más detallados. RODRIGUES et al (2016) señalan que la variabilidad en el comportamiento espacial y las causas de incendios parece estar aumentando en los últimos años. TEDIM et al (2016) muestran que los incendios en Europa son cada vez más complejos y relacionan cada vez más variables humanas y naturales a escalas locales. El modelo predictivo presentado en este trabajo considera cuatro elementos fundamentales: una escala territorial y espacial adecuada, variables socioeconómicas y biofísicas relevantes, y un método estadístico robusto.

Las áreas forestales han demostrado constituir unidades espaciales muy adecuadas que presentan ciertas ventajas sobre las más tradicionales, como los municipios, que no responden a ningún criterio forestal o de lucha contra incendios.

La baja humedad en el material vegetal y en el suelo se ha establecido como una condición necesaria para que un incendio ocurra. La modelización teniendo en cuenta variables con información directa o indirecta sobre la existencia de agua ha sido utilizada en modelos clásicos (ANDREWS et al, 2003), para determinar índices de riesgo de incendios (THOMPSON & CALKIN,

2011) y en modelos más actuales (PRICE et al 2015; URBIETA et al 2015, BOUBETA et al, 2015, RÍOS-PENA et al, 2017). Las tres variables que explican el efecto de la climatología sobre la probabilidad de incendios consideradas en este trabajo son: días sin lluvia (*dwr*), lluvia acumulada (*accumRain*) y temperatura media (*averTemp*). Tal y como señalan YIANKOULIAS & KIELASINSKA (2015), y MOLINA-TORREN & CARDIL (2016), cada vez van a tener más importancia en el contexto del cambio climático y el aumento de la temperatura media.

Entre las variables socioeconómicas analizadas, hemos usado el tamaño de la población (*pop*). La presencia de esta variable en el modelo propuesto está en la línea de autores como GANTEAUME et al (2013) y KHABAROV et al (2016), que establecen que la densidad de población debe ser considerada como uno de los factores explicativos para estudiar los incendios en Europa. A nivel regional BOUBETA et al (2015); BARREAL y LOUREIRO (2015) también han utilizado variables poblacionales en sus modelos.

Finalmente, la influencia en el comportamiento de los incendios de variables ligadas al territorio, tal como distribución de la propiedad (*cadHold*) y uso forestal (*forestArea*), se presta a diferentes interpretaciones. La mayor fragmentación del suelo entre propietarios puede explicar una mayor conflictividad entre ellos y consecuentemente un mayor número de incendios como señalan GÓMEZ-VÁZQUEZ et al (2009), MAREY-PÉREZ et al (2010, 2012), COMAS et al (2014) y CABALLERO (2015). El uso forestal arbolado del territorio sólo estaría justificado en situaciones en las que los propietarios tuviesen cierta seguridad en la inversión y los incendios no fuesen un riesgo elevado.

6. Conclusiones

En este trabajo se propone un modelo de Poisson mixto con efectos aleatorios de área correlados espacialmente según un proceso SAR(1) para modelar variables respuesta tales como el número de incendios por área. Bajo este modelo se ha obtenido el estimador MM de los parámetros del modelo y se ha propuesto un estimador plug-in donde el vector de efectos aleatorios se estima mediante el EBP. Además se propone un algoritmo bootstrap, basado en un bootstrap paramétrico, para medir la precisión del estimador.

La metodología desarrollada se aplica al caso real de incendios forestales por áreas en Galicia durante el verano del 2008. El rendimiento del estimador plug-in se compara frente a competidores tales como el modelo de Poisson de efectos fijos. Se observa una clara mejora cuando uno usa modelos de mayor complejidad. Además, dado que el p-valor del test de Moran I sugiere rechazar la hipótesis nula de no correlación espacial, en esta aplicación es más adecuado el uso de un modelo de correlación espacial SAR(1), en lugar del modelo con efectos aleatorios independientes. El estimador propuesto tiene una tasa media de error del 25,98%.

7. Agradecimientos

Este trabajo es respaldado por los proyectos MTM2015-64842-P, MTM2014-52876-R y MTM2013-41383P del Ministerio de Ciencia e Innovación del Gobierno de España.

8. Bibliografía

ALVAREZ-DÍAZ, M.; GONZÁLEZ-GÓMEZ, M.; OTERO-GIRÁLDEZ, M.S.; 2015. Detecting the socioeconomic driving forces of the fire catastrophe in NW Spain. *European Journal of Forest Research*, 134, 1087-1094.

ANDREWS, P.L.; LOFTSGAARDEN, D.O. & L.S. BRADSHOW, 2003: Evaluation of fire danger rating indexes using logistic regression and percentile analysis. *International Journal of Wildland Fire*, 12, 213-226.

BARREAL, J., LOUREIRO, M.L., 2015. Modelling spatial patterns and temporal trends of wildfires in Galicia (NW Spain). *Forest System*. 24 (2), e022.

BOUBETA, M.; LOMBARDIA, M. J.; MAREY-PÉREZ, M.; MORALES, D.; 2015. Prediction of forest fires occurrences with area-level Poisson mixed models. *Journal of Environmental Management*, 154, 151–158.

BOUBETA, M.; LOMBARDIA, M.J.; GONZÁLEZ-MANTEIGA, W.; MAREY-PÉREZ, M.; 2016. Burned area prediction with semiparametric models. *International Journal of Wildland Fire*, 25, 669–678.

CABALLERO, G. 2015. Community-based forestmanagement institutions in the Galician communal forests: A new institutional approach. *Forest Policy and Economics* 50, 347–356.

COMAS, C.; COSTAFREDA-AUMEDES, S.; VEGA-GARCÍA, C. 2014. Characterizing configurations of fire ignition points through spatiotemporal point processes. *Natural Hazards and Earth System Sciences* 2, 2891–2911.

DEMIDENKO, E.; 2004. Mixed models: theory and applications. J. Wiley.

FERNANDES, P.A.M.; 2008. Forest fires in Galicia (Spain): The outcome of unbalanced fire management. *Journal of Forest Economics*, 14, 155–157.

GÓMEZ-VÁZQUEZ, I.,ÁLVAREZ-ÁLVAREZ, P.,MAREY-PÉREZ,M.F., 2009. Conflicts as enhancers or barriers to the management of privately owned common land: a method to analyze the role of conflicts on a regional basis. *Forest Policy and Economics* 11, 617–627.

GANTAUME, A., JAPPIOT, M., 2013. What causes larges fires in Southern France. *Forest Ecology and Management*. 294, 76 - 85

GONZÁLEZ-ALONSO, F.; MERINO-DE-MIGUEL, S.; 2009. Integration of AWiFs and MODIS active fire data for burn mapping at regional level using the Burned Area Synergic Algorithm (BASA). *International Journal of Wildland Fire*, 18, 404–414.

GONZÁLEZ-MANTEIGA, W.; LOMBARDÍA, M.J.; MOLINA, I.; MORALES, D.; SANTAMARÍA, L.; 2007. Estimation of the mean squared error of predictors of small area linear parameters under a logistic mixed model. *Computational Statistics and Data Analysis*, 51, 2720–2733.

GONZÁLEZ-MANTEIGA, W.; LOMBARDÍA, M.J.; MOLINA, I.; MORALES, D.; SANTAMARÍA, L.; 2008a. Bootstrap mean squared error of small-area EBLUP. *Journal of Statistical Computation and Simulation*, 78, 443–462.

GONZÁLEZ-MANTEIGA, W.; LOMBARDÍA, M.J.; MOLINA, I.; MORALES, D.; SANTAMARÍA, L.; 2008b. Analytical and bootstrap approximations of prediction errors under a multivariate Fay-Herriot model. *Computational Statistics and Data Analysis*, 752, 5242–5252.

KHABAROV, N.; KRASOVSKII, A.; OBERSTEINER, M.; SWART, R.; DOSIO, A.; SAN-MIGUEL-AYANZ, J.; DURRANT, T.; CAMIA, A.; MIGLIAVACCA, M. 2016. Forest fires and adaptation options in Europe. *Regional Environmental Change* 16, 21 – 30.

MANDALLAZ, D.; YE, R.; 1997. Prediction of forest fires with Poisson models. *Canadian Journal of Forest Research*, 27, 1685–1694.

MAREY-PÉREZ, M.F., GÓMEZ-VÁZQUEZ, I., DÍAZ-VARELA, E.R., 2010. Different approaches to the social vision of communal land management: the case of Galicia (Spain). *Spanish Journal of Agricultural Research* 8, 848-863.

MAREY-PÉREZ, M.F., RODRÍGUEZ-VICENTE, V., ÁLVAREZ-LÓPEZ, C.J., 2012. Practical application of multivariant analysis techniques to the forest management of active farmers in the northwest of Spain. *Small Scale Forestry*. <http://dx.doi.org/10.1007/s11842-012-9195-1>.
Martínez,

MCCULLOCH, C.E.; SEARLE, S.R.; NEUHAUS, J.M.; 2008. Generalized, linear, and mixed models. J. Wiley.

MOLINA-TORREN, D.M.; CARDIL, A. 2015. Temperature determining larger wildland fires in NE Spain. *Theoretical and Applied Climatology* 125, 295 – 302.

PRICE, O.; BORAH, R.; BRADSTOCK, R.; PENMAN, T. 2015. An empirical wildfire risk analysis: the probability of a fire spreading to the urban interface in Sydney, Australia. *International Journal of Wildland Fire* 24, 597–606.

RIOS-PENA, L.; KNEIB, T.; CADARSO-SUÁREZ, C.; MAREY-PÉREZ, M.; 2017. Predicting the occurrence of wildfires with binary structured additive regression models. *Journal of environmental Management*, 187, 154–165.

RODRIGUES, M.; JIMÉNEZ, A.; DE LA RIVA, J. 2016. Analysis of recent spatial-temporal evolution of human driving factors of wildfires in Spain. *Natural Hazards* 84, 2049-2070.

TEDIM, F.; LEONE, V.; XANTHOPOULOS, G. 2016. A wildfire risk management concept based on a social-ecological approach in the European Union: Fire Smart Territory. *International Journal of Disaster Risk Reduction* 18, 138–153.

THOMPSON, M.P., CALKIN, D.E., 2011. Uncertainty and risk in wildland fire management: a review. *Journal of Environment Management* 92, 1895-1909.

URBIETA, I.R.; ZABALA, G.; BEDIA, J.; GUTIÉRREZ, J.M.; SAN-MIGUEL-AYANZ, J.; CAMIA, A.; KEELEY, J.E.; MORENO, J.M. 2015. Fire activity as a function of fire-weather seasonal severity and antecedent climate across spatial scales in southern Europe and Pacific western USA. *Environment Research Letter* 10, 114013.

WOTTOM, B.; MARTELL, D.; K.A., L.; 2003. Climate change and people-caused forest fire occurrence in Ontario. *Climate Change*, 60, 275–295.

YIANNAKOULIAS, N.; KIELASINSKA, E. 2015. The effect of temperature on arson incidence in Toronto, Ontario, Canada. *International Journal Biometeorology* 60, 651-661.