

Grid poblacional 2011 para España. Evaluación metodológica de diversas posibilidades de elaboración

2011 Population Grid for Spain. Methodological assessment of different construction possibilities

Francisco J. Goerlich Gisbert¹ e Isidro Cantarino Marti²

RESUMEN

Este trabajo presenta una evaluación, desde el punto de vista del usuario, de la malla regular (*grid*) de población, con resolución de 1 km², que el Instituto Nacional de Estadística (INE) ha hecho pública a partir de los resultados del Censo de Población y Viviendas 2011. Esta forma de difusión de resultados resulta muy novedosa y ofrece un gran valor analítico. Por primera vez esta información sobre la distribución espacial de la población se ha generado desde abajo (*bottom-up*) para el conjunto de España, es decir, a partir del conocimiento de las coordenadas de cada hogar, considerando como tales las del edificio donde reside. La disponibilidad de otra *grid* con idéntica resolución, elaborada por métodos de desagregación espacial a partir de la población censal por unidades administrativas e información auxiliar sobre coberturas del suelo (*top-down*), nos permite examinar las mejoras asociadas a la georreferenciación de la población acometida en el contexto de los cambios metodológicos del censo de 2011. De forma simultánea ello nos permite analizar las bondades de la *grid* censal.

¹ Universitat de València e Instituto Valenciano de Investigaciones Económicas (Ivie). Francisco.J.Goerlich@uv.es. ORCIDiD: <http://orcid.org/0000-0003-1626-525X>.

² Universidad Politécnica de Valencia. icantari@trr.upv.es. ORCIDiD: <http://orcid.org/0000-0002-9962-5734>.

PALABRAS CLAVE: rejillas de población; densidad de población; georreferenciación de la población; censos; *Top-down* versus *Bottom-up*; demografía; Sistemas de Información Geográfica (SIG).

ABSTRACT

This paper presents an evaluation, from the user point of view, of the regular population grid, with 1 km² resolution, that the Spanish National Statistical Institute (INE), has released as a product from the last Population and Dwellings Census 2011. This way of disseminating population data is novel, and has a lot of analytical potential uses, since population is no longer linked to administrative divisions. For the first time this information about the population distribution has been generated using a bottom-up approach for the whole of Spain, this is, by georeferencing the population at its place of residence. The availability of another *grid* at the same spatial resolution, but generated using a top-down approach, this is, by spatial disaggregation methods from administrative population data and other auxiliary land cover information, allow us to explore the benefits associated to georeferencing the population in the context of the methodological changes introduced by the Population and Dwellings Census 2011. At the same time, we are able to evaluate the merits of the census *grid*.

KEY WORDS: population grids; population density; population Geo-coding; census; *Top-Down* versus *Bottom-up*; demography; Geographical Information Systems (GIS).

CÓMO CITAR ESTE ARTÍCULO / CITATION: Goerlich Gisbert, Francisco J. y Cantarino Marti, Isidro (2017): “*Grid* poblacional 2011 para España. Evaluación metodológica de diversas posibilidades de elaboración”, *Estudios Geográficos*, LXXVIII/282, pp. 135-163.

1.- INTRODUCCIÓN

El Censo de Población y Viviendas 2011 realizado por Instituto Nacional de Estadística (INE, 2011) ha incorporado importantes novedades, tanto desde el punto de vista metodológico, se abandona un censo clásico para emplear una metodología basada en una combinación de registros administrativos y una gran encuesta por muestreo, como desde el punto de vista de la disponibilidad de información (Goerlich, Ruiz, Chorén y Albert, 2015). La resolución geográfica para la que el censo ofrece información ha disminuido notablemente, apenas se dispone de información para todos los municipios y la información por secciones censales es prácticamente inexistente. Sin embargo, las nuevas técnicas de los Sistemas de Información Geográfica (SIG) han irrumpido con fuerza, y una de las principales novedades del censo es la georreferenciación exhaustiva de todos los edificios con al menos una vivienda familiar. Esto ha permitido diseñar un sistema de difusión de la infor-

mación censal al margen de los límites administrativos, ya que se dispone de las coordenadas de cada hogar aproximadas por las del edificio donde reside (<http://www.ine.es/censos2011/visor/>).

Sin embargo, las coordenadas de los edificios no han formado parte de la información difundida por el censo. Si ha formado parte del sistema de difusión censal, no obstante, una aproximación al territorio no basada en la división administrativa del estado: Comunidades Autónomas, Provincias, Municipios y Secciones Censales. La directiva comunitaria INSPIRE (Directiva, 2007/2/EC), diseñada para establecer una Infraestructura para la Información Espacial en el seno de la Comunidad Europea, ha establecido una malla (*grid*) geográfica armonizada a nivel europeo (Annoni, 2005; INSPIRE, 2014) susceptible de ser utilizada como soporte para difundir información estadística tradicional. La *grid* de referencia estándar tiene resolución de 1 km². A partir de esta *grid* el INE ha incluido, entre sus sistemas de difusión, determinadas variables en este formato.

Lamentablemente la información existente en dicho formato es casi tan limitada como la disponible para las Secciones Censales. Si descargamos la información del sitio web del INE nos encontraremos con que, de los 145 indicadores potencialmente disponibles en dicho formato, solo está completa la «Población total» por celda, para el resto de indicadores siempre hay más o menos celdas en blanco por cuestiones de secreto y/o fiabilidad estadística. Adicionalmente, la población total solo incluye la residente en viviendas principales, excluyéndose de esta forma la población en establecimientos colectivos, y además se ofrece redondeada al 5 en cada celda. A pesar de estas limitaciones esta forma de difusión supone un importante paso adelante, más que por la utilidad intrínseca de la información ofrecida, por lo que representa en términos de la utilización de formatos que con seguridad se generalizarán en el futuro³. Este trabajo evalúa, desde el punto de vista metodológico, la *grid* de población derivada del censo de 2011. Esta no es la primera *grid* de población disponible para toda España, pero sí la primera construida a partir de una georreferenciación puntual de la población, es decir, mediante métodos conocidos como *bottom-up* (EFGS, 2014). Sin embargo, la *grid* procedente del INE

³ Durante el proceso de elaboración de este trabajo el INE (2015) difundió una interesante publicación sobre las características básicas de la sociedad española a partir de este sistema zonal y la información del censo de 2011. Lamentablemente la información disponible al público es bastante inferior a la necesaria para la realización de dicho trabajo, pero muestra las potencialidades descriptivas de dicho formato. El trabajo muestra, también, los avances cartográficos realizados desde el censo de 1991, en el que, por primera vez, se puso sobre un mapa la densidad de población de los municipios españoles (INE, 1994).

objeto de evaluación en este trabajo no es la que procede del sitio web del Instituto, sino la que distribuye Eurostat⁴. Dicha *grid* tiene algunas ventajas respecto a la ofrecida directamente por el INE en su web. En primer lugar no está redondeada al 5, sino que ofrece cifras de población entera por celda sin ningún tipo de restricción de confidencialidad. En segundo lugar, incluye el total de la población, tanto la residente en viviendas principales como en establecimientos colectivos, y en consecuencia es consistente con el total de población censal. En lo sucesivo esta *grid* será referenciada como *GEOSTAT2011*.

La estructura del trabajo es la siguiente. En primer lugar examinamos, brevemente, las *grids* de población disponibles para el conjunto nacional desde una perspectiva histórica, así como sus métodos de producción. Adicionalmente, se genera una *grid* a partir de la población del censo y métodos dasimétricos de desagregación espacial, conocidos generalmente como *top-down*. Dada la obvia superioridad de los métodos *bottom-up*, la sección siguiente examina el origen de los errores cometidos normalmente por los métodos de desagregación que utilizan coberturas del suelo como información auxiliar. Esto permite examinar hasta qué punto dichos métodos pueden mejorar la calidad de la información, y que tipos de errores serán inevitables independientemente de los algoritmos de desagregación empleados. A continuación evaluamos directamente la *grid* del INE frente a un fichero de coordenadas puntuales de la población, ya que toda la información que disponemos del INE es a nivel de celda de 1 km² de resolución. Una sección final resume las conclusiones del trabajo.

2.– CENSUS GRID 2011: UN POCO DE HISTORIA

La primera distribución de la población para España en formato de malla geográfica regular procede del censo de 2001 y fue realizada por el Joint Research Centre (JRC) de la Comisión Europea (Gallego, 2010; Gallego, Batista, Rocha y Mubareka, 2011)⁵. El objetivo último era disponer de estadísticas de población, a nivel europeo, que no dependieran de límites administrativos, y

⁴ Véase <http://ec.europa.eu/eurostat/web/gisco/geodata/reference-data/population-distribution-demography>.

⁵ Esta pequeña reseña histórica obvia los proyectos de cobertura mundial realizados mediante teledetección y en los que también está incluida España (Bhaduri, Bright, Coleman y Dobson, 2002; CIESIN, 2005; Bhaduri, Bright, Coleman y Urban, 2007). Tampoco se incluyen otros trabajos nacionales de desagregación de la población y que no cubren la totalidad del territorio nacional (Vinuesa, 1976; De Cos, 2004; García y Cebrián, 2006; Ojeda, Márquez y Álvarez, 2012; Santos Preciado, 2015).

que fueran almacenadas en un sistema zonal que permitiera la integración con otro tipo de información, fundamentalmente medioambiental. Esta *grid* es distribuida por la Agencia Europea del Medio Ambiente (EEA)⁶.

Dicha *grid* fue elaborada mediante métodos dasimétricos de desagregación espacial (Eicher y Brewer, 2001) a partir de las poblaciones municipales del censo de 2001 y *Corine Land Cover (CLC)* como información auxiliar. En aquel momento no fue posible evaluar la calidad de los resultados para España, puesto que no existía población georreferenciada respecto a la que comparar la bondad de los métodos utilizados. Una distribución de la población en este formato representaba una mejora sustancial respecto al cálculo de densidades por municipios tradicional, y que supone implícitamente que todo el territorio que sirve de soporte a la cifra de población está habitado. Sin embargo, y a pesar de dicha mejora, la distribución generada no era muy realista. Para España suponía que, a escala de una cuadrícula de 1 km², el 85% del territorio tenía población residente. Dicha dispersión está muy lejos de la realidad, dado el modelo de asentamiento del interior y sur peninsular. El origen del problema procedía fundamentalmente de la baja resolución de la información auxiliar utilizada en el proceso de desagregación: *Corine Land Cover*, la base de datos sobre coberturas del suelo de referencia a escala europea. Tal y como muestran Goerlich y Cantarino (2012) el modelo de asentamiento de una gran parte de España, junto con la resolución de *CLC* produce que en más de la mitad de los municipios españoles *CLC* no reporte zona urbana. El resultado es que el algoritmo de desagregación dispersa en exceso la población sobre coberturas agrícolas, y más generalmente sobre zonas del territorio que no están habitadas. En consecuencia, la densidad de población en zonas urbanas es infraestimada y la densidad de población en zonas rurales es sobrestimada.

Una amplia evidencia en la literatura sobre desagregación espacial mediante métodos dasimétricos muestra como la resolución de la información auxiliar utilizada en el proceso de desagregación es mucho más importante que la fineza de los algoritmos (Martin, Tate y Langford, 2000), y claramente la resolución de *CLC* aplicada sobre datos municipales era insuficiente para producir resultados satisfactorios.

Eurostat se marcó como objetivo disponer de una *grid* de población a escala europea con referencia 2006. Dicha malla debería mejorar la de 2001, por lo que, para aquellos países que no disponían de población georreferenciada los esfuerzos se dirigieron a aumentar la resolución de la información auxiliar.

⁶ Véase <http://www.eea.europa.eu/data-and-maps/data/population-density-disaggregated-with-corine-land-cover-2000-2>.

A nivel europeo se hicieron ensayos con la capa de sellado del suelo⁷, 1 ha de resolución (Steinocher, 2011a, 2011b), así como intentos de mejorar *CLC* con información adicional de mayor resolución (Batista e Silva, 2011; Batista e Silva, Lavalle, y Koomen, 2013). Afortunadamente, para España se hizo público el *Sistema de Información de Ocupación del Suelo de España* (SIOSE, IGN 2011) con fecha de referencia 2005, que además de presentar una resolución mucho mayor que *CLC*, desarrollaba un modelo de datos con mucha mayor información que el listado de coberturas jerárquico de *CLC*.

A partir de la población por sección censal procedente del Padrón, lo que supone una importante mejora de resolución especialmente en el ámbito urbano, y aprovechando todo lo posible el modelo de datos de *SIOSE2005*, Goerlich y Cantarino (2011, 2012, 2013) elaboraron una *grid* de población para España que fuera incorporada a la *grid* europea distribuida por Eurostat, conocida como *GEOSTAT2006*. Esta *grid* fue validada frente al Padrón georreferenciado de la Comunidad de Madrid, con un error relativo del 4%, muy reducido frente a los errores reportados por Gallego (2010) y Gallego, Batista, Rocha y Mubareka (2011) para los países en los que podía efectuarse esta validación en 2001, y que se situaba entre el 17% y el 35%.

Los algoritmos de desagregación aplicados resultaron ser similares a los utilizados anteriormente para la elaboración de la *grid* de 2001, por lo que las mejoras logradas pueden atribuirse a la mayor resolución de la información poblacional de partida, secciones censales *versus* municipios, así como a la de la información auxiliar sobre coberturas del suelo, que en el caso de *SIOSE* incluso contiene información sobre el tipo de edificación. El resultado fue un 19% de celdas de 1 km² con población residente, una cifra notablemente inferior a la obtenida en 2001. La tabla 1 compara la distribución relativa de frecuencias de ambas *grids* y permite observar a simple vista sus diferencias: en la de 2001 un 63% de las celdas tienen menos de 20 habitantes, en la de 2006 ese porcentaje no llega a la mitad, 29%. Lo contrario sucede en el otro extremo de la distribución. Las celdas que tienen al menos 500 habitantes en 2001 apenas llegan al 2%, pero superan el 11% en 2006. Estas diferencias son todavía más acusadas en los extremos. En definitiva, la distribución de la población que se deriva de la *grid* de 2006 es notablemente más concentrada que la que mostraba su predecesora, y este efecto se debe, en exclusividad, a la mayor resolución de la información empleada en su elaboración.

⁷ Distribuida por Copernicus, *The European Earth Observation Programme*, dependiente de la Comisión Europea y de la EEA. Véase <http://land.copernicus.eu/pan-european/high-resolution-layers/imperviousness/view>.

TABLA I
RESUMEN DE LAS PRINCIPALES CARACTERÍSTICAS DE LAS GRIDS DE POBLACIÓN PARA ESPAÑA: 2001, 2006 Y 2011
(a) Información sobre celdas habitadas

N.º	Fecha de referencia	Origen de la población	Promotor de la grid	Productor de la grid	Celdas habitadas Absolutas	Celdas habitadas %	Distribución de frecuencias por tamaño de población en las celdas					
							< 5	5 - 19	20 - 199	200 - 499	500 - 4999	>= 5000
1	2001	Censo	EEA	JRC	434.738	85,0%	124.295	147.886	146.847	5.632	8.577	1.501
							28,6%	34,0%	33,8%	1,3%	2,0%	0,3%
2	2006	Padrón	Eurostat	UVEG/UPV	94.916	18,6%	8.823	19.124	46.047	9.793	9.258	1.871
							9,3%	20,1%	48,5%	10,3%	9,8%	2,0%
3	2011	Censo	Eurostat	INE	63.522	12,4%	2.800	10.881	30.036	7.893	9.740	2.172
							4,4%	17,1%	47,3%	12,4%	15,3%	3,4%
4	2011	Censo	Goerlich y Cantarino (2014)	INE	95.169	18,6%	9.411	20.407	44.131	9.414	9.750	2.056
							9,9%	21,4%	46,4%	9,9%	10,2%	2,2%
5	2011	Censo	INE	INE	62.440	12,2%	0	11.484	31.107	7.945	9.750	2.154
							0,0%	18,4%	49,8%	12,7%	15,6%	3,4%

(b) Información sobre población en la grid

N.º	Fecha de referencia	Origen de la población	Promotor de la grid	Productor de la grid	Población Absoluta	Población en la grid %	Distribución de frecuencias por tamaño de población en las celdas					
							< 5	5 - 19	20 - 199	200 - 499	500 - 4999	>= 5000
1	2001	Censo	EEA	JRC	40.874.775	100,1%	270.194	1.602.814	7.292.006	1.783.650	13.344.865	16.581.246
							0,7%	3,9%	17,8%	4,4%	32,6%	40,6%
2	2006	Padrón	Eurostat	UVEG/UPV	44.708.964	100,0%	20.229	215.917	3.323.510	3.068.789	13.954.561	24.125.958
							0,0%	0,5%	7,4%	6,9%	31,2%	54,0%
3	2011	Censo	Eurostat	INE	46.816.043	100,0%	7.912	123.455	2.250.465	2.500.596	15.410.678	26.522.937
							0,0%	0,3%	4,8%	5,3%	32,9%	56,7%
4	2011	Censo	Goerlich y Cantarino (2014)	INE	46.689.142	99,7%	21.674	229.071	3.147.629	2.961.097	14.953.164	25.376.507
							0,0%	0,5%	6,7%	6,3%	32,0%	54,4%
5	2011	Censo	INE	INE	46.574.735	99,5%	0	108.715	2.252.000	2.500.505	15.416.830	26.296.685
							0,0%	0,2%	4,8%	5,4%	33,1%	56,5%

Nota: Los estadísticos de la grid del JRC de 2001 se han obtenido de la extracción de la capa europea, sin ajuste en la población de las celdas frontera. Fuente: EEA: Agencia Europea del Medio Ambiente, JRC: Joint Research Centre (Comisión Europea), UVEG/UPV: Universitat de Valencia Estudi General / Universidad Politécnica de Valencia, Goerlich y Cantarino (2012, 2013), (2014), Instituto Nacional de Estadística.

La *grid* de 2006 representaba un objetivo intermedio hasta la realización del censo de 2011, el primero elaborado bajo reglamentación europea. De dicho censo se obtendría la tercera *grid* europea, y a ser posible debía generarse mediante métodos de georreferenciación de la población a nivel de coordenada puntual, por lo que una vez disponible la base de datos de coordenadas y población asignada a las mismas, la obtención de la *grid* debería ser inmediata. La georreferenciación de todos los edificios con alguna vivienda proporciona el marco ideal para que el INE generara una *grid* de población *bottom-up* a partir del censo de 2011, lo que significa un salto cualitativo metodológico importante frente a sus dos predecesoras anteriores, 2001 y 2006, generadas ambas por métodos *top-down*.

La tabla 1 muestra las características principales de la *grid* producida por el INE a partir del censo y distribuida por Eurostat, *GEOSTAT2011*⁸. La superficie habitada, a 1 km² de resolución, apenas supera el 12% del territorio nacional, lo que supone 1/3 menos de celdas habitadas respecto a la de 2006. La distribución de frecuencias muestra de nuevo las importantes diferencias; si bien estas no son notables en el centro de la distribución, se acentúan en los extremos: el porcentaje de celdas con menos de 20 habitantes apenas supera el 21%, mientras que las celdas con más de 500 habitantes casi alcanzan el 19%. *GEOSTAT2011* muestra, pues, una concentración de la población realmente elevada, no solo el porcentaje de celdas habitadas es notablemente menor que en *GEOSTAT2006*, sino que dichas celdas presentan una elevada concentración con un número realmente escaso de celdas con menos de 5 habitantes (4,4%), algo menos de la mitad que en 2006. Las diferencias son, en cualquier caso, mucho menores que entre las *grids* de 2001 y 2006.

Las diferencias entre las distribuciones de 2001 y 2006 pueden atribuirse con claridad a cuestiones relacionadas con la resolución de la información de base, ya que el método estadístico de distribución de la población es muy similar en ambos casos. Las diferencias entre *GEOSTAT2006* y *GEOSTAT2011* pueden deberse tanto al método de producción, *top-down* versus *bottom-up*, como a cambios reales en la concentración de la población. El periodo intercensal 2001-2011 resulta ser el de mayor crecimiento poblacional de la historia, casi 6

⁸ La tabla 1 también muestra, en la fila 5, los estadísticos básicos para la *grid* distribuida por el INE en su sitio web, lo que deja patente porque dicha *grid* no puede utilizarse para un ejercicio de esta naturaleza. No solo esta *grid* no recoge el total de la población, excluyendo la residente en establecimientos colectivos, sino que además el proceso de redondeo al 5 sesga los resultados hacia una mayor concentración de la población: ¡No hay celdas con población inferior a los 5 habitantes, aunque existan, ya que los valores inferiores a 2,5 se redondean a 0!

millones de personas, en gran parte debido a la inmigración; y este *stock* de nuevos efectivos no se ha distribuido en modo alguno de forma uniforme a lo largo del territorio (Goerlich, Ruiz, Chorén y Albert, 2015). Para aislar el efecto de los diferentes métodos de producción del lapso temporal entre ambas rejillas de población, Goerlich y Cantarino (2014) aplicaron la misma metodología empleada en la elaboración de *GEOSTAT2006* a la población por secciones censales del censo de 2011 y *SIOSE2009* como información auxiliar en el proceso de desagregación. El resultado resumido de dicho ejercicio se muestra en la fila 4 de la tabla 1. Observamos cómo dicha actualización no afecta prácticamente en nada a la distribución de la población mostrada en *GEOSTAT2006*. El mensaje principal de dicho ejercicio resulta pues bastante claro: las diferencias entre la distribución de la población mostradas en *GEOSTAT2006* y *GEOSTAT2011* se deben, en su práctica totalidad, a los métodos de producción, y no a cambios apreciables en la distribución de la población a la escala de referencia, celdas de 1 km².

3.- TOP-DOWN VERSUS BOTTOM-UP: ¿DÓNDE FRACASAN LOS MÉTODOS DE DESAGREGACIÓN ESPACIAL?

Esta sección compara *GEOSTAT2011* con la *grid top-down* generada por Goerlich y Cantarino (2014) a partir de la población del censo de 2011 y *SIOSE2009*. El ejercicio toma como base de comparación *GEOSTAT2011*, puesto que los métodos *bottom-up* son superiores a cualquier método estadístico de desagregación espacial, que por su propia naturaleza solo puede aspirar a aproximar la realidad. En consecuencia nos preguntamos dónde fracasan los métodos *top-down*. El análisis es relevante porque no siempre es posible disponer de una *grid* construida a partir de población georreferenciada, y en consecuencia ejercicios de desagregación continuarán siendo inevitables en el futuro, quizá para características de la población u otras variables, pero el tipo de errores cometidos por los algoritmos dasimétricos de reescalado espacial son de naturaleza similar en la mayoría de los casos. El apartado siguiente cambiará la base de comparación, al objeto de evaluar la bondad de *GEOSTAT2011*.

El estadístico estándar para evaluar las discrepancias respecto a una *grid* de referencia es $\frac{1}{2}$ del error relativo total, que se encuentra comprendido entre 0 y 1:

$$\delta = \frac{\sum_{i=1}^n |P_i - P_i^{ref}|}{2 \times P^{ref}} \quad (1)$$

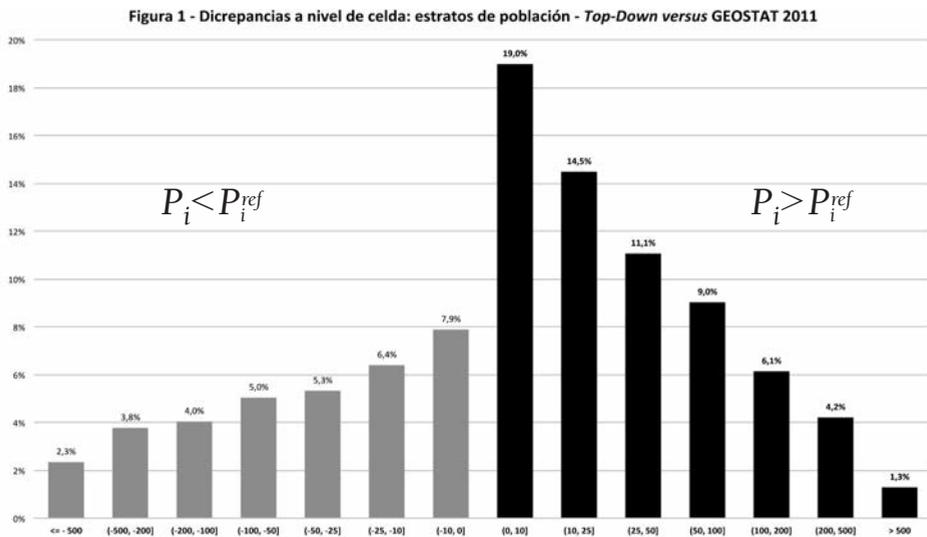
donde P_i^{ref} es la población de la *grid* de referencia, *GEOSTAT2011*, P_i la de la *grid* objeto de comparación generada mediante desagregación, n son el número de celdas de la malla, y $P^{ref} = \sum_{i=1}^n P_i^{ref}$. Dicho estadístico alcanza un valor del 10,1% en nuestro caso, en el entorno del doble de lo obtenido para la Comunidad de Madrid en la elaboración de *GEOSTAT2006*.

El coeficiente de correlación, calculado entre las poblaciones de las celdas, es de 0,99 entre ambas *grids*. Esta elevada correlación, unida a un error relativo moderado, y la importante discrepancia entre el número de celdas habitadas generada por ambos métodos de producción (tabla 1), tienden a indicar que las discrepancias se concentran en un número relativamente grande de celdas, pero que afectan a poca población.

La figura 1 ofrece una primera comprobación de esta intuición. En ella mostramos el histograma de discrepancias por estratos de población distinguiendo los casos en los que $P_i > P_i^{ref}$, a la parte derecha, de los casos en los que $P_i < P_i^{ref}$, a la parte izquierda de la figura. El 20% de los errores se concentran en casos en los que la discrepancia no supera los 10 habitantes y $P_i > P_i^{ref}$. Casi la mitad de los errores (45%) se encuentran dentro de esta tipología, $P_i > P_i^{ref}$, y la población afectada no supera los 50 habitantes por celda.

FIGURA 1

DISCREPANCIAS A NIVEL DE CELDA: ESTRATO DE POBLACIÓN – TOP DOWN VERSUS GEOSTAT2011



Fuente: Eurostat para *GEOSTAT2011* y elaboración propia (Goerlich y Cantarino 2014).

Para un análisis detallado de errores conviene clasificar las celdas de la *grid top-down* en tres grupos: (i) ‘falsos positivos’, cuando dicha *grid* asigna población pero la de referencia no, (ii) ‘falsos negativos’, cuando dicha *grid* no asigna población a la celda en cuestión, pero la de referencia sí, y (iii) ‘celdas correctas’, en el sentido de que presentan población en ambas *grids*, aunque su magnitud no tiene necesariamente que coincidir. El error relativo (1) se descompone de forma nítida en estos tres componentes:

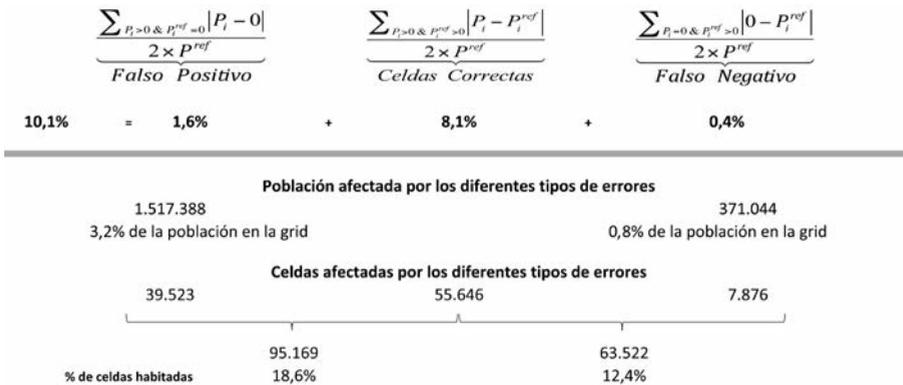
$$\delta = \underbrace{\frac{\sum_{P_i > 0 \ \& \ P_i^{ref} = 0} |P_i - 0|}{2 \times P^{ref}}}_{\text{Falso Positivo}} + \underbrace{\frac{\sum_{P_i > 0 \ \& \ P_i^{ref} > 0} |P_i - P_i^{ref}|}{2 \times P^{ref}}}_{\text{Celdas Correctas}} + \underbrace{\frac{\sum_{P_i = 0 \ \& \ P_i^{ref} > 0} |0 - P_i^{ref}|}{2 \times P^{ref}}}_{\text{Falso Negativo}} \quad (2)$$

Lo que permite examinar no solo las celdas discrepantes, sino también la magnitud de las discrepancias en términos de población. La figura 2 ofrece esta descomposición y confirma las intuiciones anteriores: aunque en términos de celdas afectadas los errores cometidos por nuestra desagregación son elevados, un 42% de las celdas de la *grid top-down* (95,169) son ‘falsos positivos’, y un 12% de las celdas de *GEOSTAT2011* (63,522) son ‘falsos negativos’ —la desagregación dasimétrica no asigna población cuando en realidad si la hay—, la población afectada es poco relevante. Tan solo un 3% de la población es asignada a celdas realmente deshabitadas, mientras que un porcentaje inferior al 1% no se asigna correctamente a celdas con población según *GEOSTAT2011*.

FIGURA 2

DESCOMPOSICIÓN DEL ERROR RELATIVO EN TRES COMPONENTES: FALSOS POSITIVOS VERSUS FALSOS NEGATIVOS.

COMPARACIÓN *GEOSTAT2011* VERSUS *GRID TOP-DOWN*



Fuente: Eurostat para *GEOSTAT2011* y elaboración propia a partir de Goerlich y Cantarino (2014).

El resultado es, como ya se mencionó al principio, que los métodos de desagregación espacial tienden a dispersar en exceso la población, esto se manifiesta en un número relativamente elevado de celdas que no están realmente habitadas «falsos positivos», aunque no afecta a volúmenes de población importantes. La existencia del error contrario, no asignar población a celdas que «falsos negativos», es mucho menos frecuente, pero no despreciable, y su origen debe ser analizado.

Resulta de interés examinar si existe un patrón de discrepancias a nivel provincial. Dada una partición del territorio en G regiones, exhaustivas y mutuamente excluyentes del territorio nacional, el error relativo se descompone como una suma ponderada de los errores cometidos en las diferentes regiones:

$$\delta = \frac{\sum_{i=1}^n |P_i - P_i^{ref}|}{2 \times P^{ref}} = \sum_{g=1}^G \frac{P_g^{ref}}{P^{ref}} \cdot \frac{\sum_{i=1}^{n_g} |P_{i,g} - P_{i,g}^{ref}|}{2 \times P_g^{ref}} = \sum_{g=1}^G \frac{P_g^{ref}}{P^{ref}} \cdot \delta_g \quad (3)$$

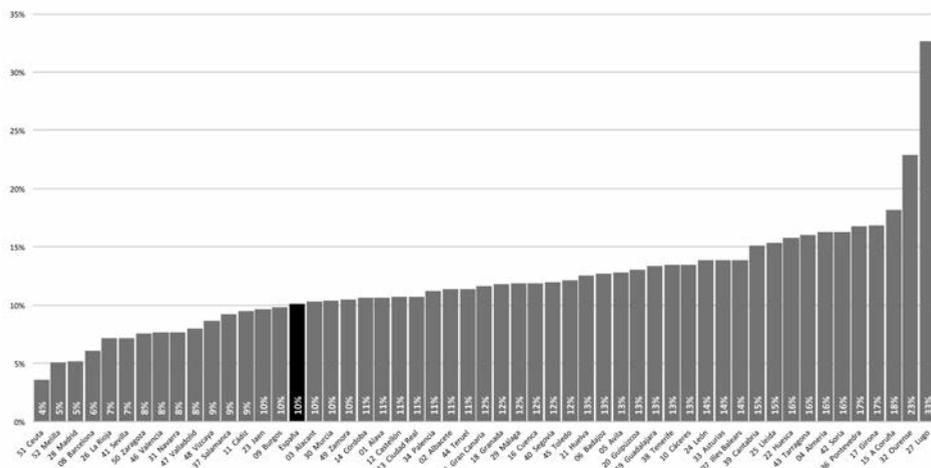
El análisis de los errores a nivel provincial, $G = 52$, reveló la existencia de un patrón espacial muy marcado asociado a los diferentes tipos de asentamiento dentro del conjunto nacional. Como revela la figura 3, exceptuando Ceuta y Melilla, los errores oscilan entre un 5% para Madrid y un 33% para Lugo. Sin embargo, lo más interesante de dicha figura es que los errores son claramente menores en provincias con una población muy concentrada y asentada sobre núcleos compactos, como Madrid, Barcelona, Sevilla, Zaragoza o Valencia. Mientras que los errores son muy elevados en provincias con población dispersa, entre las cinco provincias con los errores más elevados se encuentran las cuatro gallegas.

Lo que la figura 3 muestra es que el error cometido en los procesos de desagregación depende no solo de la resolución de la información de partida, sino también del patrón de asentamiento de la población, o alternativamente que dicho patrón afecta a la calidad de la información auxiliar dado un grado de resolución de la misma.

Un análisis detallado, en muchos casos mediante inspección visual sobre ortofotos, de los falsos positivos y falsos negativos mostró que los métodos de desagregación fracasan fundamentalmente en tres direcciones, algunas de ellas no son responsabilidad del algoritmo de desagregación, sino de la calidad —o la resolución— en la información de partida o de decisiones del propio investigador⁹:

⁹ No incluimos en este listado desajustes geométricos entre las capas de la información auxiliar, SIOSE en nuestro ejercicio, y el fichero vectorial de contornos administrativos de la población objeto de desagregación, las secciones censales en nuestro caso.

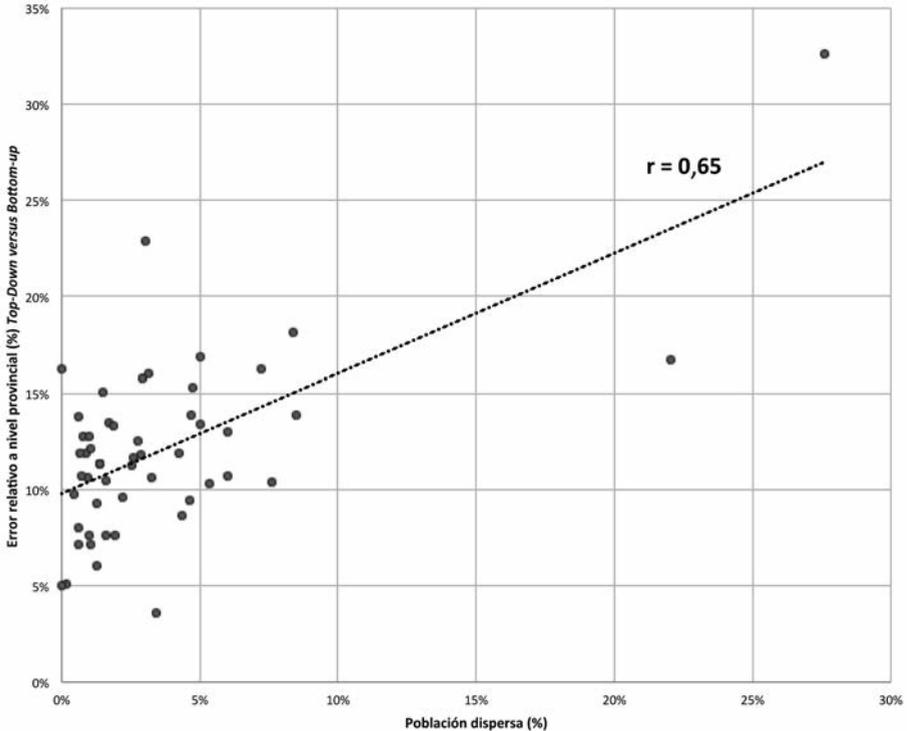
FIGURA 3

ERROR RELATIVO A NIVEL PROVINCIAL: *TOP-DOWN VERSUS GEOSTAT2011*

Ambos tipos de errores de asignación de la población son más frecuentes cuando la población es dispersa, que cuando está más concentrada sobre el territorio, tal y como muestra la figura 4 a nivel provincial¹¹.

FIGURA 4

ERROR RELATIVO VERSUS DISPERSIÓN EN LA POBLACIÓN A NIVEL PROVINCIAL



Fuente: Eurostat para *GEOSTAT2011*, INE-Nomenclátor 2012, para la población dispersa, y elaboración propia a partir de Goerlich y Cantarino (2014).

2. Viviendas convencionales no principales (secundarias o vacías): Inevitable cuando la información auxiliar en el proceso de desagregación procede de las coberturas del suelo, que no incluye información sobre usos

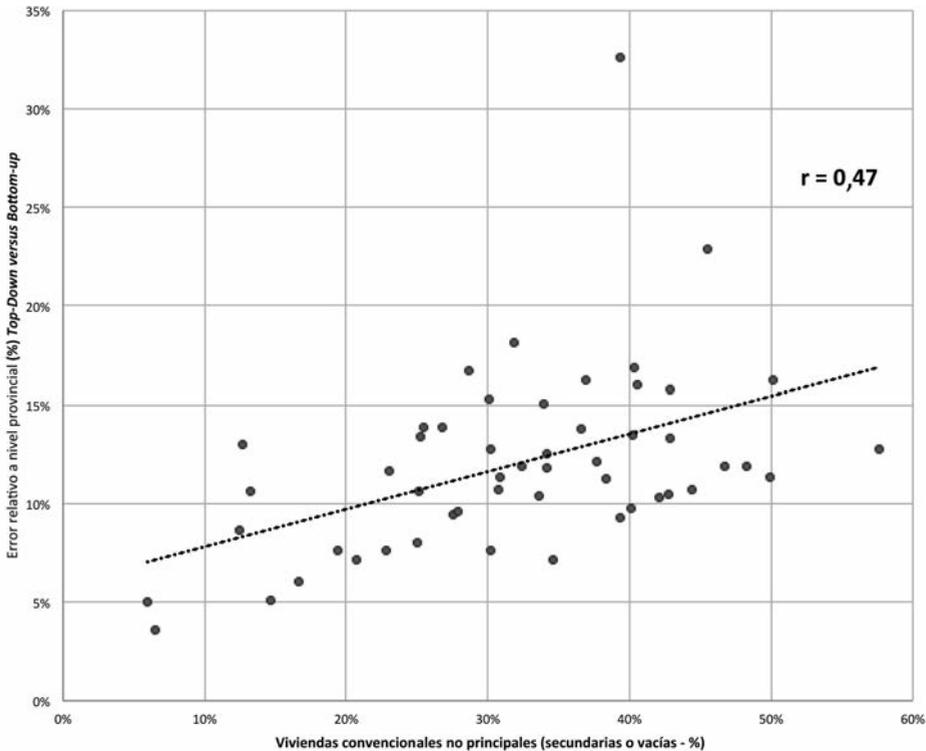
¹¹ Excluyendo las dos provincias con mayor valor de población dispersa, Lugo y Pontevedra, que destacan sobremanera en la figura 4, el coeficiente de correlación sigue siendo positivo, aunque disminuye hasta un valor de 0,36.

de la vivienda, tal y como es nuestro caso. Por su propia naturaleza ello genera falsos positivos, ya que el algoritmo de desagregación asigna población a viviendas no ocupadas con carácter residencial.

Este factor puede explicar, en gran parte, el exceso en el número de celdas habitadas que arroja la *grid top-down* frente a *GEOSTAT2011*, figura 2, ya que de acuerdo con la información del censo de 2011 el 28% de las viviendas convencionales son viviendas secundarias o vacías, y por tanto no albergan población residente. La figura 5 muestra, a nivel provincial, una clara relación positiva entre el número de viviendas no principales y el error cometido en el proceso de desagregación.

FIGURA 5

ERROR RELATIVO VERSUS VIVIENDAS SECUNDARIAS O VACÍAS A NIVEL PROVINCIAL



Fuente: Eurostat para *GEOSTAT2011*, INE-Censo de 2011 y elaboración propia a partir de Goerlich y Cantarino (2014).

3. Decisiones sobre ‘donde vive la población’. Cualquier ejercicio dasimétrico de desagregación espacial requiere de una decisión a priori sobre qué coberturas van a soportar población y cuáles no. Esta selección condicional, de partida, los resultados finales y puede generar tanto falsos positivos, al seleccionar coberturas que pueden albergar población, pero que finalmente no la tienen, como —más frecuentemente— falsos negativos, al impedir asignar población a coberturas que realmente si la tienen.

Esta es una decisión difícil, en la que el investigador tiene que alcanzar un equilibrio entre ambos tipos de errores, normalmente con información muy limitada al respecto¹².

La figura 6 muestra un caso concreto, y real, de esta situación, se trata del Monasterio de Santa María del Paular, en la provincia de Madrid. SIOSE clasifica el polígono —contorno negro en la figura 6— como complejo religioso —cobertura compuesta *ERG*—, nuestra selección de coberturas al generar la *grid top-down* no permite población en este tipo de coberturas, y en consecuencia no asignamos población a una celda que en realidad si la tiene. Generamos de esta forma un falso negativo en nuestra *grid*. Una comparación con la población georreferenciada muestra que en dicho lugar residen 9 personas —punto negro en la figura 6—, que deberían ser adecuadamente tenidas en cuenta por una *grid bottom-up*, que asignaría correctamente esa población a la celda correspondiente.

Sin embargo, si permitiéramos que las coberturas de tipo complejo religioso albergaran población con generalidad entonces la mayor parte de ellas resultarían habitadas, cuando en la práctica no lo están. Así pues, el investigador debe realizar una elección difícil en un contexto de incertidumbre, y en el que reglas generales no son probablemente de aplicación. Incluso los denominados métodos dasimétricos ‘inteligentes’ (Mennis y Hultgren, 2006), basados en el muestreo empírico para determinar pesos variables por tipo de cobertura para la redistribución de la población, no están exentos de este tipo de error. Los pesos determinados en una parte del territorio pueden no ser de aplicación en otra. El análisis anterior muestra claramente como el patrón de asentamiento poblacional influye de forma notable sobre la magnitud del error en la desagregación.

Una cuantificación de cada una de estas fuentes de error sobre el error total en la generación de la *grid top-down* frente a *GEOSTAT2011* es muy difícil, entre otras cosas porque dichos errores están muy correlacionados, y a su vez son dependientes de la resolución de la información de partida.

¹² Tal y como sugiere un evaluador anónimo esta fuente de errores podría reducirse en gran medida mediante la utilización de datos catastrales.

FIGURA 6

FALSO NEGATIVO DEBIDO A LA SELECCIÓN DE COBERTURAS



Fuente: SIOSE 2009, IEM- Padrón 2012 y elaboración propia.

4.- UNA EVALUACIÓN DIRECTA DE *GEOSTAT2011*

La sección anterior compara la desagregación espacial de la población del censo de 2011 a un formato de malla regular de 1 km² de resolución, utilizando *SIOSE2009* como información auxiliar y las secciones censales como unidad estadística para la población, con la *grid GEOSTAT2011*, disponible a la misma escala y ofrecida directamente por Eurostat a partir de la georreferenciación de la población proveniente del censo de 2011.

Dichas coordenadas, que son las que soportan la *grid*, o las de los edificios con alguna vivienda familiar fruto de la operación censal, no son información pública. En consecuencia, a nivel nacional la comparación que hemos efectuado en la sección anterior es todo lo que podemos realizar. Y es suficientemente ilustrativa de que los métodos dasimétricos de desagregación espacial tienden a dispersar la población más de lo que debieran, incluso cuando la información de partida es de muy elevada resolución.

Sin embargo, al igual que para la *grid GEOSTAT2006* (Goerlich y Cantarino, 2012) disponemos del Padrón 2012 para la Comunidad de Madrid georreferenciado. Dicho fichero contiene las coordenadas de las Aproximaciones

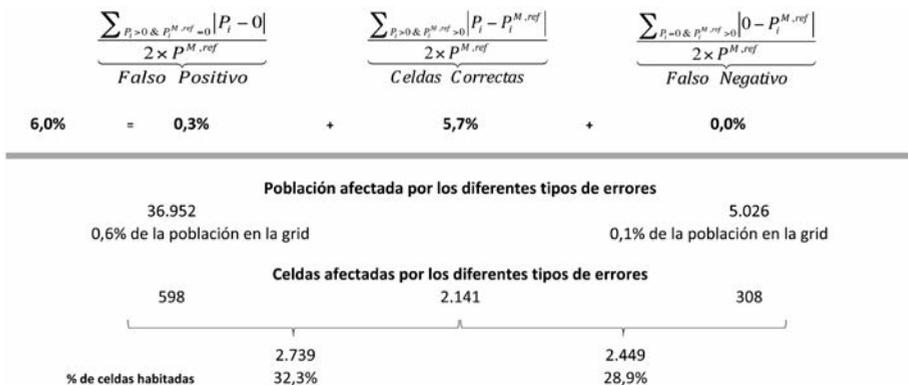
Postales Principales (APP) del 99,4% de la población del Padrón, y a partir de él es directo obtener una *grid* a la resolución que se desee. Para celdas de 1 km² dicha *grid* contiene 2449 celdas habitadas, un 30% del total. Podemos suponer que el error de dicha *grid* es prácticamente nulo, y representa la verdadera distribución de la población a la escala considerada.

Si comparamos la *grid top-down* para Madrid con la generada por agregación de coordenadas —*bottom-up*— el error relativo es del 6%, solo ligeramente superior al que obteníamos para *GEOSTAT2006* (Goerlich y Cantarino, 2012), y muy similar al que se obtiene para esa provincia cuando *GEOSTAT2011* se toma como *grid* de referencia (5%) —figura 3—. Por su estructura de asentamiento urbano, Madrid es la provincia que muestra menor error entre los métodos *top-down* y *bottom-up*.

La descomposición de dicho error, entre «falsos positivos» y «falsos negativos», así como las celdas implicadas en dichos errores y la población afectada por los mismos, se muestra en la figura 7. El patrón de errores es muy similar al descrito en la sección anterior. La *grid* generada por desagregación muestra un mayor número de celdas habitadas que la obtenida a partir de las coordenadas puntuales, 32% frente a 29%, aunque las celdas con ‘falso positivo’ están muy poco habitadas, por lo que la población afectada es muy escasa. En términos de población, los «falsos negativos» son prácticamente inexistentes, de forma que los errores de los métodos de desagregación se manifiestan en una mayor dispersión de la que observamos en la realidad.

FIGURA 7

DESCOMPOSICIÓN DEL ERROR RELATIVO EN TRES COMPONENTES: FALSOS POSITIVOS VERSUS FALSOS NEGATIVOS
COMPARACIÓN GRID BOTTOM-UP MADRID VERSUS GRID TOP-DOWN



Fuente: IEM-Padrón 2012 georreferenciado y elaboración propia a partir de Goerlich y Cantarino (2014).

Un análisis a nivel municipal permitió confirmar que las discrepancias están asociadas a la dispersión de la población y al volumen de viviendas no principales, secundarias o vacías. Aunque, más allá de estas características generales, un patrón definido de los errores es difícil de encontrar.

No obstante, la disponibilidad de la población georreferenciada para la Comunidad de Madrid nos permite comparar dos *grids bottom-up*, *GEOSTAT2011* y la construida directamente por nosotros para Madrid. Ambas deberían ser prácticamente idénticas, ya que el desfase temporal entre la fecha de referencia es de solo dos meses y las poblaciones en ambas *grids* difieren en solo un 0,2%.

Sin embargo, las celdas habitadas para Madrid que reporta *GEOSTAT2011* son 1,948, un 23%, lo que en términos absolutos supone 501 celdas habitadas menos, y 7 puntos porcentuales de diferencia. *GEOSTAT2011* parece concentrar la población más de lo que encontramos en la realidad, si esta la juzgamos a partir de la *grid* generada para Madrid.

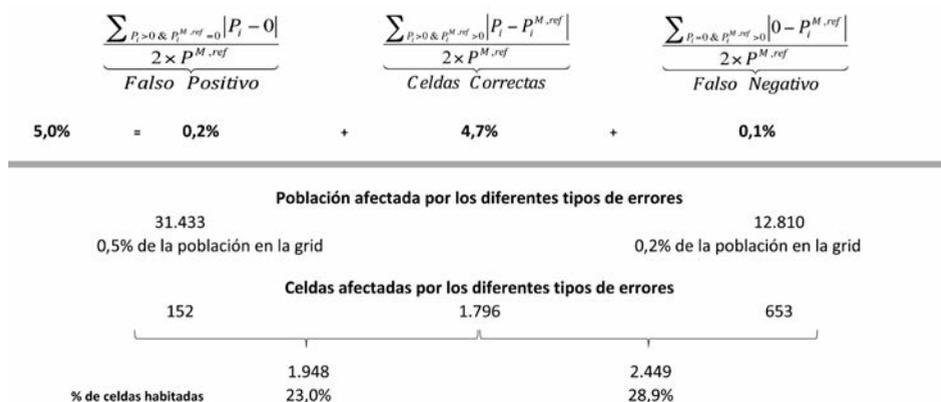
Ciertamente esta discrepancia no es despreciable, sobre todo si tenemos en cuenta que Madrid es la región donde los errores tienden a ser menores —figura 3—, por lo que estas cifras representan, probablemente, una cota inferior a la magnitud de las discrepancias entre ambas *grids*, aunque las dos hayan sido producidas mediante métodos similares.

El error relativo entre ambas resulta ser del 5%. La descomposición de dicho error se muestra en la figura 8, y aunque de nuevo la población afectada por los errores ‘falso positivo’ y ‘falso negativo’ es escasa, dicha figura muestra, en términos de celdas, el patrón inverso al observado en la figura 7: las celdas en la que *GEOSTAT2011* no atribuye población, ‘falsos negativos’, pero las coordenadas del Padrón indican que si la hay, son relativamente numerosas, 653, lo que representan un 27% del total de celdas habitadas según el Padrón. Ciertamente la población en dichas celdas es muy reducida, curiosamente bastante inferior a la población afectada por los «falsos positivos», a pesar de que, en este caso, el número de celdas donde *GEOSTAT2011* asigna población, pero el Padrón no, es muy bajo, del orden del 8%¹³.

¹³ Es difícil pensar en una explicación para este hecho, que quizá se deba, parcialmente, a la población de Padrón no georreferenciada, alrededor de unas cuarenta mil personas.

FIGURA 8

DESCOMPOSICIÓN DEL ERROR RELATIVO EN TRES COMPONENTES: FALSOS POSITIVOS VERSUS FALSOS NEGATIVOS
COMPARACIÓN GRID BOTTOM-UP MADRID VERSUS GEOSTAT2011



Fuente: IEM-Padrón 2012 georreferenciado y Eurostat para GEOSTAT2011.

El mensaje general que se desprende de la comparación de las figuras 7 y 8 es doble. Primero, tomando la *grid bottom-up* de Madrid como referencia, los métodos de desagregación espacial tienden a dispersar en exceso la población, aun cuando la resolución de la información utilizada en el proceso de desagregación sea elevada, pero esto afecta a volúmenes de población poco importantes. Esta conclusión ya la habíamos observado, y ha sido repetidamente señalada por la literatura (Gallego, 2010).

Segundo, un mensaje algo más sorprendente, *GEOSTAT2011* tiende a concentrar la población más de lo que debiera en términos de celdas habitadas. En conjunto, si los resultados mostrados en las figuras 7 y 8 fueran extrapolables a nivel nacional, cálculos aproximados indicarían que el porcentaje de celdas habitadas que debería mostrar una *grid* censal, generada a partir de coordenadas de la población, debería situarse en el entorno del 16% del total, es decir unas ochenta mil celdas habitadas, aproximadamente a medio camino entre la *grid top-down* y *GEOSTAT2011*¹⁴. Es cierto, no obstante, que estamos

¹⁴ Estos cálculos simplemente mantienen la estructura relativa entre las tres *grids* que aparecen en las figuras 7 y 8, y la extrapola al total nacional.

hablando de diferencias en términos de población afectada en el margen, es decir, pequeñas en ambos casos, y cuyo error relativo probablemente se mantendría alrededor del 10%.

La cuestión de interés es buscarle una explicación a las diferencias entre la *grid* para la Comunidad de Madrid, generada a partir de coordenadas puntuales, y *GEOSTAT2011*, que en principio sigue el mismo método de producción —figura 8—. En ambos casos se trata de *grids bottom-up* construidas a partir de ficheros de población georreferenciada. En la metodología censal lo único que se indica es que este tipo de producto, no dependiente de las unidades estadísticas tradicionales de recogida de la información, «[...] puede realizarse dado que cada hogar tiene asignadas unas coordenadas GPS aproximadas (las del edificio donde habita)» (INE, 2011: 96). En consecuencia, la explicación que ofrecemos a continuación es tentativa y exploratoria.

Estimamos que el problema reviste cierto interés, no solo por ofrecer una explicación a las discrepancias observadas, sino fundamentalmente porque puede ayudar a mejorar los métodos de desagregación espacial, o incluso los procedimientos *bottom-up* bajo determinadas circunstancias, cuando la información disponible no es completa (Enrique, Molina, Ojeda, Escudero y Pérez, 2013; Kraus, Moravec y Klauda, 2013).

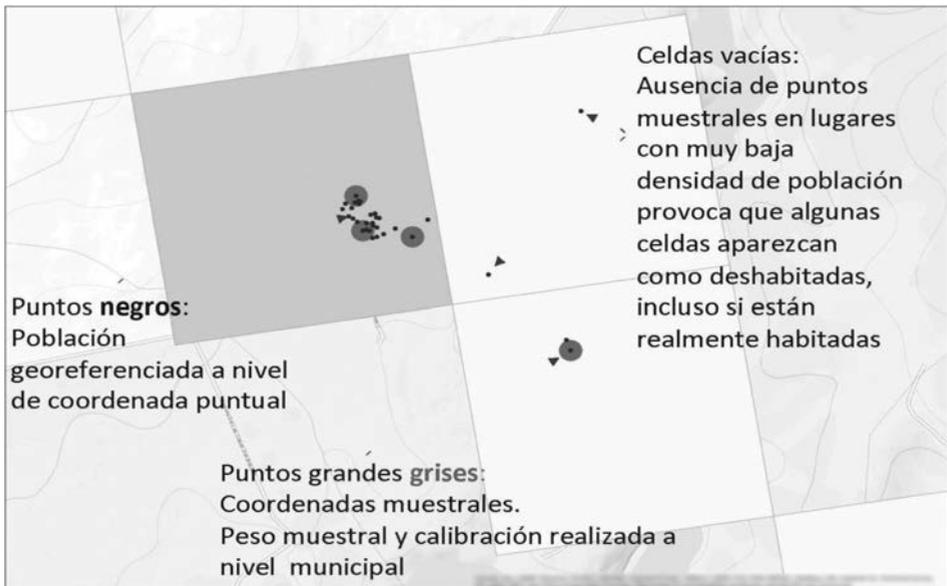
La explicación más razonable de las discrepancias observadas vuelve sobre la metodología censal con la que hemos iniciado el trabajo. El censo de 2011 ha adoptado una metodología mixta, en la que el recuento de la población y sus características demográficas básicas proceden de un ajuste del Padrón, como fichero básico de referencia de la población residente, pero el resto de características procede de una gran encuesta por muestreo, cuya fracción de muestro teórica estaba diseñada para el 12% de la población y que en la práctica se ha visto reducida al 9%. No obstante, se selecciona muestra en todas las secciones censales (INE, 2011; Goerlich, Ruiz, Chorén y Albert, 2015: cap. 1).

Aunque el censo prevé una georreferenciación exhaustiva de los edificios con alguna vivienda familiar, principal o no, con lo que en principio cabría pensar que la georreferenciación podría haberse llevado a cabo a partir del fichero precensal —al menos para el total de población y sus características básicas—, en la práctica la georreferenciación de los hogares se ha producido para la muestra recogida. El resultado es que, aunque la literatura sobre generación de *grids* de población ha discutido ampliamente dos métodos de producción, *top-down versus bottom-up* (EFGS, 2012), el INE ha llevado a cabo una versión de *bottom-up* que podríamos denominar *survey bottom-up*. En esta versión la *grid* se genera a partir de coordenadas puntuales, pero dichas coordenadas llevan asociado un peso muestral como el registro de cualquier en-

cuesta. Naturalmente, la bondad de la estimación finalmente resultante depende del diseño muestral en relación con la escala a la que deseamos ofrecer información, pero como todas las celdas habitadas no han sido objeto de muestreo —ni sería factible, ni se conocen a priori— la *grid* resultante no puede cubrir todas las celdas realmente habitadas. Lo más frecuente serán errores de ‘falsos negativos’ en celdas con muy poca densidad de población, ya que en estas celdas la probabilidad de seleccionar algún hogar será muy baja. Adicionalmente los factores de elevación, calibrados para los municipios, serán representativos a esta escala, pero no tienen por qué serlo a nivel de celda. Estos aspectos de diseño muestral espacial (Kumar, 2012; Wang, Stein, Gao y Ge, 2012) no han sido tenidos en cuenta, lo que tiene cierto impacto sobre los resultados finales, tanto en términos de celdas habitadas como de población residente en las mismas. La figura 9 trata de ilustrar visualmente esta idea, y proporciona cierta intuición del elevado número de ‘falsos negativos’, así como de la magnitud de error relativo de *GEOSTAT2011* en comparación con la *grid* de la Comunidad de Madrid, tal y como se muestra en la figura 8.

FIGURA 9

ILUSTRACIÓN DEL EFECTO DEL MUESTREO DE COORDENADAS SOBRE LA GENERACIÓN DE UN *GRID* DE POBLACIÓN *BOTTOM-UP*



Fuente: IEM-Padrón 2012 georeferenciado y Eurostat para *GEOSTAT2011*.

Es posible ofrecer alguna evidencia que trate de corroborar esta intuición. En primer lugar, una inspección directa de las coordenadas de Padrón frente a las celdas de *GEOSTAT2011* parece confirmar el argumento anterior. La figura 10 ofrece un ejemplo, y permite observar con claridad cómo *GEOSTAT2011* deja escapar con relativa facilidad varias coordenadas con población —puntos negros en la figura 10—, mientras que en las zonas con una densidad elevada de puntos las celdas se identifican correctamente.

FIGURA 10
POBLACIÓN GEORREFERENCIADA DE PADRÓN FRENTE A CELDAS DE
GEOSTAT2011



Nota: Puntos grises: coordenadas con población de Padrón 2012.
Fuente: IEM- Padrón 2012 georreferenciado y Eurostat para *GEOSTAT2011*.

En segundo lugar, es posible examinar de forma aproximada el efecto que un muestreo similar al del censo —aunque obviamente no idéntico— tiene sobre la generación de una *grid* de población mediante el método que hemos denominado *survey bottom-up*. Nuestro fichero de población georreferenciada para la Comunidad de Madrid dispone no solo del número de personas por coordenada, sino también del número de hogares, y del tamaño de cada uno de

ellos en dicha coordenada. En consecuencia podemos simular mediante Monte Carlo el proceso seguido por el censo en la generación de *GEOSTAT2011*¹⁵.

Para ello se determinó el municipio y la sección censal de cada coordenada, y se asignaron fracciones de muestreo según el tamaño municipal (INE, 2011: 79). Dicha muestra se distribuyó proporcionalmente al tamaño en cada sección censal, y se supuso una tasa de respuesta del 90%. Se introdujo la restricción de que debía haber muestra en todas las secciones censales, de al menos un hogar. A continuación, una vez seleccionada la muestra, los factores de elevación se calcularon como la inversa de la probabilidad de selección y se ajustaron —calibraron— al total de la población a nivel municipal. Finalmente, la muestra seleccionada, convenientemente ponderada por los factores de elevación estimados, se proyectó sobre las celdas de la *grid*, y se calcularon dos estadísticos frente a la *grid* generada directamente a partir de las coordenadas de la población georreferenciada: (i) las celdas que dan error ‘falso negativo’, y (ii) el error relativo total.

Este proceso se replicó 1000 veces. En promedio, las celdas con «falso negativo» fueron 522, con un error estándar de 12, lo que representa un 21% del total de las celdas con población; no muy lejos de lo observado en la figura 8 para *GEOSTAT2011*, donde las celdas con ‘falso negativo’ representan un 27%. Si hemos de otorgar alguna fiabilidad a estas cifras, lo que nos indican, extrapolando los resultados al total nacional, es que las celdas habitadas derivadas de la *grid* censal deberían estar más cerca de las ochenta mil, que de las sesenta y tres mil actuales que indica *GEOSTAT2011*. Estas celdas, sin embargo, estarían muy poco pobladas. En el ejercicio de Monte Carlo recogen solo el 0,1% de la población, el mismo porcentaje que el observado en la figura 8. El error relativo promedio, derivado del ejercicio de simulación, es del 7,9%, con un error estándar de 0,9. Algo más elevado de que lo que observamos en la figura 8 para *GEOSTAT2011*.

¹⁵ Este ejercicio es solo una aproximación por varias razones. En primer lugar, el muestreo del ejercicio de Monte Carlo solo es una aproximación al seguido en el censo de 2011. La unidad secundaria de muestreo en el censo es la vivienda familiar —ocupada o no—, mientras que nosotros muestreamos directamente hogares, lo que es asimilable a viviendas principales, de forma que no tenemos el problema de las viviendas secundarias o vacías. En segundo lugar, nuestro muestreo aplica la fracción de muestreo teórica del censo y supone una tasa de respuesta uniforme del 90%. Dentro de cada sección censal la muestra es proporcional a su tamaño. No disponemos de dos marcos de hogares con distinto proceso de selección de la muestra como en el caso del censo (INE, 2011: sec. 8). En tercer lugar, los factores de elevación simplemente escalan la muestra al total de la población municipal, sin incorporar ningún otro tipo de información adicional.

Ciertamente el ejercicio de simulación no puede explicar todas las diferencias observadas, pero ilustra de forma clara lo que las figuras 9 y 10 muestran de forma visual: las *grids survey bottom-up* concentran la población más de lo que debieran, justo al contrario que las *grids top-down*.

5.— CONCLUSIONES

Este trabajo ha presentado brevemente una comparación de la *grid* de población derivada del censo de 2011, elaborada a partir de coordenadas puntuales de la población, frente a una actualización de su inmediata predecesora, *GEOSTAT2006*, generada por métodos dasimétricos de desagregación espacial a partir de los datos de población del propio censo y *SIOSE2009* como información auxiliar.

Ello ha permitido corroborar un resultado ya conocido. Los métodos de desagregación espacial dispersan en exceso la población. Un análisis de las fuentes de error permiten descubrir un marcado patrón espacial de las discrepancias, que pueden explicarse por tres factores fundamentales: (i) el tipo de asentamiento poblacional, disperso *versus* concentrado, (ii) el problema de las viviendas no principales, que no es tenido en cuenta en el proceso de desagregación, y (iii) las propias decisiones del analista sobre qué coberturas soportan población residente. El análisis también ha puesto de manifiesto que, aunque las diferencias en términos del número de celdas son notables, las que hacen referencia a la población son mucho menores. Aunque muchas de estas conclusiones aparecen de forma dispersa en la literatura, el análisis efectuado ofrece una clasificación sistemática de las mismas, así como una cuantificación del posible origen de las discrepancias encontradas en nuestro caso concreto.

La disponibilidad de un fichero georreferenciado de población para la Comunidad de Madrid nos ha permitido evaluar ambas *grids* frente a una generada por nosotros mismos por agregación de dichas coordenadas. Para la *grid top-down* las conclusiones son básicamente las mismas que las que acabamos de señalar en el párrafo anterior. La comparación frente a *GEOSTAT2011* muestra algunos resultados de interés. Por una parte, dicha *grid* parece concentrar la población más de lo que debiera, es decir, muestra menos celdas habitadas de las que existen en la realidad. Ello es debido, casi con total seguridad, a un efecto diseño, es decir, a que la georreferenciación de la población se ha efectuado para la muestra del censo, y no para toda la población recogida en el mismo —el fichero precensal ponderado—. Por otra parte, este

efecto de concentración, aun abarcando a un número de celdas no despreciable, no afecta a grandes volúmenes de población, sino más bien al contrario, se trata de celdas con muy baja densidad, y en muchos casos aisladas de los núcleos principales.

Hasta donde nosotros conocemos este método de elaborar *grids* de población, al que hemos denominado *survey bottom-up*, es novedoso y no ha sido empleado con anterioridad. La literatura ha concentrado sus esfuerzos en describir y depurar, o bien métodos estadísticos de desagregación espacial con información auxiliar —*top-down*—, o bien en normalizar la producción de estadísticas de población georreferenciada —*bottom-up*— (EFGS, 2012; 2014). Dada la novedad del método, es necesario, sin embargo, evaluar la bondad del mismo en situaciones mucho más generales que las tratadas en este trabajo. Para ello será inevitable, no solo el análisis de casos concretos, sino también la incorporación de los métodos de muestreo espacial a este problema particular, con el objetivo de cuantificar el error cometido en la generación de *grids* de población a diferentes escalas.

AGRADECIMIENTOS

Francisco J. Goerlich agradece la ayuda del proyecto ECO2015-70632-R, “El desarrollo en la era de la economía digital y sus condicionantes: aspectos metodológicos y análisis empírico” del Ministerio de Ciencia y Tecnología.

Este trabajo ha evolucionado a partir de la presentación *Comparing bottom-up and top-down population density grids: The Spanish Census 2011*, en el *European Forum for Geography and Statistics (EFGS) Conference 2014*, 22-24 de octubre, Cracovia, Polonia. Los autores agradecen los comentarios de los participantes en dicho foro, y en particular los de Ignacio Duque (INE), Jorge Luis Vega (INE), Carmen Teijeiro (INE) y Matina Halkia (JRC); así como los comentarios de dos evaluadores anónimos que mejoraron notablemente la primera versión del trabajo. Agradecemos la disponibilidad a facilitarnos información para la Comunidad de Madrid de Ángel Sánchez (IEM), Dolores Núñez (IEM) y Rosario Arenas (IEM). Una parte importante de este trabajo no hubiera sido posible sin los datos de la Comunidad de Madrid que amablemente pusieron a nuestra disposición.

Resultados mencionados en el texto pero no ofrecidos están disponibles si se solicitan a los autores.

REFERENCIAS

- Annoni, A. (ed.) (2005): *European Reference Grids*, EUR Report 21494 EN, Ispra (Italia), Institute for Environment and Sustainability (IES) y Comisión Europea, Joint Research Centre, 193 pp. [*Proceedings of the European Reference Grids Workshop*, Ispra (Italia), 27-29 de octubre de 2003], <http://www.ec-gis.org/sdi/publist/pdfs/annoni2005eurgrids.pdf> (fecha de consulta: 02/05/2017).
- Batista e Silva, F. (2011): "The effect of ancillary data in population dasymetric mapping: A test case using the original and a modified version of CORINE Land Cover", presentado en el *European Forum for Geography and Statistics Conference* (EFGS), Lisboa (Portugal), 12-14 de octubre de 2011.
- Batista e Silva, F., Lavalle, C. y Koomen, E. (2013): "A procedure to obtain a refined European land use/cover map", *Journal of Land Use Science*, 8/3, pp. 255-283.
- Bhaduri, B., Bright, E., Coleman, P. y Dobson, J. (2002): "LandScan: Locating people is what matters", *Geoinformatics*, 5/2, pp. 34-37, <http://www.ornl.gov/sci/landscan/> (fecha de consulta: 02/05/2017).
- Bhaduri, B., Bright, E., Coleman, P. y Urban, M. L. (2007): "LandScan USA: a high-resolution geospatial and temporal modeling approach for population distribution and dynamics", *GeoJournal*, 69, pp. 103-117, <http://www.ornl.gov/sci/landscan/> (fecha de consulta: 02/05/2017).
- CIESIN (Center for International Earth Science Information Network) (2005): *Gridded Population of the World (GPW), Versión 3*, Palisades (NY), CIESIN, Columbia University, <http://sedac.ciesin.columbia.edu/> (fecha de consulta: 02/05/2017).
- De Cos Guerra, Olga (2004): "Valoración del método de densidades focales (*kernel*) para la identificación de los patrones espaciales de crecimiento de la población de España", *Geofocus*, 4, pp. 136-165.
- EFGS (European Forum for Geography and Statistics) (2012): *GEOSTAT 1A Final Report – Representing Census data in a European population grid*, Kongsvinger (Noruega), European Forum for Geography and Statistics, http://ec.europa.eu/eurostat/documents/4311134/4350174/ESSnet-project-GEOSTAT1A-final-report_0.pdf/fc048569-bc1c-4d99-9597-0ea0716efac3 (fecha de consulta: 30/1/2015).
- EFGS (European Forum for Geography and Statistics) (2014): *GEOSTAT 1B Final Report*, Kongsvinger (Noruega), European Forum for Geography and Statistics, <http://www.efgs.info/geostat/1B> (fecha de consulta: 30/1/2015).
- Eicher, C. y Brewer, C. (2001): "Dasymetric mapping and areal interpolation: Implementation and evaluation", *Cartography and Geographic Information Science*, 28, pp. 125-138.
- Enrique Regueira, I., Molina Trapero, J. E., Ojeda Casares, S., Escudero Tena, M. y Pérez Morales, G. (2013): "A population grid for Andalusia" Instituto de Estadística y Cartografía de Andalucía, 7 de septiembre de 2013.

- Gallego, F. J. (2010): "A population density grid of the European Union", *Population & Environment*, 31/6 (julio), pp. 460-473, <http://www.springerlink.com/content/0199-0039/31/6/>, (fecha de consulta: 02/05/2017).
- Gallego, F. J., Batista, F., Rocha, C. y Mubareka, S. (2011): "Disaggregating population density of the European Union with CORINE land cover", *International Journal of Geographical Information Science*, 25/12, pp. 2051-2069, <http://dx.doi.org/10.1080/13658816.2011.583653> (fecha de consulta: 02/05/2017).
- García González, J. A. y Cebrián Abellán, F. (2006): "La interpolación como método de representación cartográfica para la distribución de la población: Aplicación a la provincia de Albacete", ponencia presentada en el XII Congreso Nacional de Tecnologías de la Información Geográfica, Granada, 19-23 de septiembre de 2006.
- Goerlich, F. J. y Cantarino, I. (2011): "Population Grid for Spain – SIOSE", presentado en el *European Forum for Geography and Statistics Conference (EFGS)*, Lisboa (Portugal), 12-14 de octubre de 2011.
- Goerlich, F. J. y Cantarino, I. (2012): *Una grid de densidad poblacional para España. Informe Economía y Sociedad*, Bilbao, Fundación BBVA, 182 pp.
- Goerlich, F. J. y Cantarino, I. (2013): "A population density grid for Spain", *International Journal of Geographical Information Science*, 27/12, pp. 2051-2069, <http://dx.doi.org/10.1080/13658816.2013.799283> (fecha de consulta: 02/05/2017).
- Goerlich, F. J. y Cantarino, I. (2014): "Comparing bottom-up and top-down population density grids: The Spanish Census 2011", presentado en el *European Forum for Geography and Statistics Conference (EFGS)*, Cracovia (Polonia), 22-24 de octubre de 2014.
- Goerlich, F. J., Ruiz, F., Chorén, P. y Albert, C. (2015): *Cambios en la estructura y localización de la población: una visión de largo plazo (1842-2011)*, Bilbao, Fundación BBVA, 354 pp.
- IGN (Instituto Geográfico Nacional) (2011): *Sistema de Información de Ocupación del Suelo en España —SIOSE2005—*. Documento Resumen, Madrid, 10 de mayo de 2011 <http://www.siose.es/> (fecha de consulta: 02/05/2017).
- INE (Instituto Nacional de Estadística) (1994): *Densidad de Población de los Municipios Españoles. Mapas Provinciales. Censos de Población y Viviendas 1991*, Madrid.
- INE (Instituto Nacional de Estadística) (2011): *Proyecto de los Censos Demográficos 2011*, Madrid, Subdirección General de Estadísticas de la Población, febrero.
- INE (Instituto Nacional de Estadística) (2015): *¿Cómo es España? 25 mapas para descubrirla km² a km²*, Madrid, Subdirección General de Estadísticas de la Población, enero, http://www.ine.es/ss/Satellite?L=0&c=INEPublicacion_C&cid=1259945920521&p=1254735110672&pagename=ProductosYServicios%2FPYSLayOut¶m1=PYSDetalleGratuitas (fecha de consulta: 20/1/2015).
- INSPIRE (Infrastructure for spatial information in Europe) (2014): *D2.8.I.2 INSPIRE Specification on Geographical Grid Systems – Guidelines*, INSPIRE Thematic Working Group Coordinate Reference Systems and Geographical Grid Systems. Version 3.1 (2014-04-17), <http://inspire.jrc.ec.europa.eu/index.cfm/pageid/2> (fecha de consulta: 02/05/2017).

- Kraus, J., Moravec, S. y Klauđa, P. (2013): "Disaggregation Methods For Georeferencing Inhabitants With Unknown Place Of Residence: The Case Study Of Population Census 2011 In The Czech Republic", *Appendix 16 WP1B de EFGS (2014)*, disponible en <http://www.efgs.info/geostat/1B> (fecha de consulta: 30/1/2015).
- Kumar, N. (2012): "Spatial sampling design for a demographic and health survey", *Population Research Policy Review*, 26/5, pp. 581-599.
- Martin, D., Tate, N. J. y Langford, M. (2000): "Refining population surface models: Experiments with Northern Ireland Census data", *Transactions in GIS*, 3, pp. 285-301.
- Mennis, J. y Hultgren, T. (2006): "Intelligent dasymetric mapping and its application to areal interpolation", *Cartography and Geographic Information Science*, 33/3, pp. 179-194.
- Ojeda, J., Márquez, J. y Álvarez, J. I. (2012): "Análisis de redes y sensibilidad a la unidad mínima de información poblacional: Sanlúcar de Barrameda (Cádiz)", en *XV Congreso Nacional de Tecnologías de la Información Geográfica, AGE-CSIC*, Madrid.
- Santos Preciado, J. M. (2015): "La cartografía catastral y su utilización en la desagregación de la población. Aplicación al análisis de la distribución espacial de la población en el municipio de Leganés (Madrid)", *Estudios Geográficos*, LXXVI/278, pp. 309-333.
- Steinocher, K. (2011a): "The European Dataset: The disaggregation issue", presentado en el *European Forum for Geography and Statistics Conference (EFGS)*, Lisboa (Portugal). 12-14 de octubre de 2011.
- Steinocher, K. (2011b): "A new population grid for Europe – chances and challenges", presentado en el *European Forum for Geography and Statistics Conference (EFGS)*, Lisboa (Portugal), 12-14 de octubre de 2011.
- Vinuesa Angulo, J. (1976): *El Desarrollo Metropolitano de Madrid: Sus Repercusiones Geodemográficas*, Madrid, Instituto de Estudios Madrileños, 364 pp.
- Wang, J. F., Stein, A., Gao, B. B. y Ge, Y. (2012): "A review of spatial sampling". *Spatial Statistics*, 2, pp. 1-14.

Fecha de recepción: 11 de febrero de 2015.

Fecha de aceptación: 9 de septiembre de 2015.