



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA

---

# Metodología espacio-temporal con datos de panel. Estudio de la mortalidad europea.

Septiembre de 2017

---

Autora: Patricia Carracedo Garnateo

Directora: Ana Debón Aucejo



# Agradecimientos

En primer lugar quiero dar las gracias a mi directora Ana Debón por su excelente trabajo, paciencia y confianza desde el Trabajo Fin de Máster hasta la Tesis Doctoral. Gracias por ser mi madre académica, gran parte de lo que soy es gracias ti.

Debo extender este agradecimiento a Paco Montes y Adina Iftimi, por toda la ayuda prestada durante este tiempo. Sin ellos, esta tesis no hubiera sido posible.

A José Manuel Guaita, por confiar en mí para formar parte del equipo de la *Valencian International University*.

A Rosa Mari, Isabel, Joani, Silvia y Natalia mis grandes amigas.

A toda mi familia, en especial a mis padres, hermano y iaia por su ayuda y apoyo incondicional durante estos años.

A mi marido, por su comprensión, apoyo y cariño.

Finalmente, al Ministerio de Economía y Competitividad por el apoyo económico a este trabajo mediante el proyecto MTM2013-45381-P.

---

*a Claudia, mi hija*



# Resumen

En los últimos años, la brecha de mortalidad entre los países del este y del oeste de Europa está aumentando. Por ello, recientemente se han aplicado diversos estudios para analizar las diferencias de la mortalidad europea. Para detectar agrupaciones de mortalidad similar, urge la necesidad de extender los estudios actuales con estudios espaciales, los cuales tienen en cuenta la ubicación geográfica de los países, el tiempo y su interacción.

La presente tesis doctoral pretende servir de ayuda tanto a las políticas públicas para que éstas puedan realizar una distribución eficiente de recursos como a los actuarios, los cuales elaboran seguros de vida y diseñan los planes pensiones. En este contexto, se proponen tres objetivos principales. El primero, se centra en mostrar cómo estandarizar la tasa bruta de mortalidad para poder realizar comparaciones entre países. El segundo, se basa en la presentación y aplicación de una metodología espacio-temporal basada en datos de panel para llevar a cabo la identificación de agrupaciones significativas de países europeos con mortalidad similar a lo largo del tiempo. El tercero, versa en la propuesta y adaptación de una metodología espacio-temporal para seleccionar el mejor modelo espacial de datos de panel con el fin de modelizar de forma correcta el efecto espacial y el temporal. El modelo final se validó utilizando dos medidas de bondad de ajuste: la varianza residual y el coeficiente de determinación. Finalmente, las rutinas para seccionar el mejor modelo espacial se implementaron en R.

La metodología estadística detallada a nivel teórico se aplica a datos de mortalidad de 26 países europeos para un rango de edad comprendido entre 0 a

---

110+ y un horizonte temporal de más de 15 años. Es de nuestro interés aplicar y mostrar esta metodología en un software estadístico libre R y, por tanto, al alcance de todos.

El trabajo realizado en la presente tesis doctoral se enmarca dentro de la línea de investigación financiada por el Ministerio de Economía y Competitividad en el proyecto MTM2013-45381-P, “Diferencias de longevidad en la Unión Europea: aplicación de nuevos métodos para su evaluación y análisis”.

# Resum

En els últims anys, la bretxa de mortalitat entre els països de l'est i de l'oest d'Europa està augmentant. Per això, recentment s'han aplicat diversos estudis per analitzar les diferències de la mortalitat europea. Per detectar agrupacions de mortalitat similar, urgeix la necessitat d'estendre els estudis actuals amb estudis espacials, els quals tenen en compte la ubicació geogràfica dels països, el temps i la seua interacció.

La present tesi doctoral pretén servir d'ajuda tant a les polítiques públiques perquè aquestes puguen realitzar una distribució eficient de recursos com als actuaris, els quals elaboren assegurances de vida i dissenyen els plans pensions. En aquest context, es proposen tres objectius principals. El primer, se centra a mostrar com estandarditzar la taxa bruta de mortalitat per poder realitzar comparacions entre països. El segon, es basa en la presentació i aplicació d'una metodologia espai-temporal basada en dades de panell per dur a terme la identificació d'agrupacions significatives de països europeus amb mortalitat similar al llarg del temps. El tercer, versa en la proposta i adaptació d'una metodologia espai-temporal per seleccionar el millor model espacial de dades de panell per tal de modelitzar de forma correcta l'efecte espacial i el temporal. El model final es va validar utilitzant dues mesures de bondat d'ajust: la variància residual i el coeficient de determinació. Finalment, les rutines per seleccionar el millor model espacial es van implementar en R.

La metodologia estadística detallada a nivell teòric s'aplica a dades de mortalitat de 26 països europeus per a un rang d'edat comprès entre 0 a 110+ i un horitzó temporal de més de 15 anys. És del nostre interès aplicar i mostrar

---

aquesta metodologia en un software estadístic lliure R i, per tant, a l'abast de tots.

El treball realitzat en la present tesi doctoral s'emmarca dins de la línia d'investigació finançada pel Ministeri d'Economia i Competitivitat en el projecte MTM2013-45381-P, "Diferencias de longevidad en la Unión Europea: aplicación de nuevos métodos para su evaluación y análisis".

# Abstract

In recent years, the mortality gap between Eastern and Western European countries is increasing. For this reason, several studies have recently been applied to analyze the differences in European mortality. In order to detect similar mortality groups, there is an urgent need to extend the current studies with spatial studies, which take into account the geographical location of countries, time and their interaction.

This doctoral thesis aims to help public policies so that they can efficiently distribute resources, as well as actuaries, who develop life insurance and design pension plans. In this context, three main objectives are proposed. The first one focuses on how to standardize the crude mortality rate for comparisons between countries. The second is based on the presentation and application of a spatio-temporal methodology based on panel data to carry out the identification of significant groups of European countries with similar mortality over time. The third one deals with the proposal and adaptation of a spatio-temporal methodology to select the best spatial panel data model in order to correctly model spatial and temporal effects. The final model was validated using two measures of goodness of fit: the residual variance and the coefficient of determination. Finally, the routines to section the best spatial model were implemented in R.

The detailed statistical methodology at the theoretical level is applied to mortality data from 26 European countries for a range between 0 to 110+ and a time range of more than 15 years. It is in our interest to apply and display this

---

methodology in a free statistical software R and, therefore, within the reach of all.

The work of this doctoral thesis is part of the research supported by the Ministry of Economy and Competitiveness in the project MTM2013-45381-P, “Longevity differences in the European Union: application of new methods for evaluation and analysis”.

# Índice general

Introducción	XI
1 Evaluar las diferencias de mortalidad en Europa	7
1.1 Introducción	8
1.2 Materiales y Métodos	11
1.3 Resultados	24
1.4 Conclusiones	39
2 Selección de modelos espaciales de datos de panel en Matlab y R	43
2.1 Introducción	43
2.2 Materiales y Métodos	45
2.3 Resultados	55
2.4 Conclusiones	73
3 Grupos de mortalidad de países europeos por sexo y edad	77
3.1 Introducción	78
3.2 Materiales y métodos	79
3.3 Resultados	88

3.4 Conclusiones . . . . .	100
4 Conclusiones y futuras líneas de investigación	105
Bibliografía	109
Apéndices	115
A	117
B	125
C	139
D	163
E	187



# Índice de figuras

1.1. Ratio de Mortalidad Estandarizada en Europa . . . . .	10
1.2. Diagrama de cajas del SMR para cada país . . . . .	25
1.3. Comportamiento del índice global de Moran en Europa . . . . .	27
1.4. Mapa clusters en Europa . . . . .	30
1.5. Representación gráfica de efectos temporales . . . . .	36
1.6. Diagrama de cajas de los residuos del modelo SLMSTFE para cada año . . . . .	38
2.1. Representación gráfica de los efectos temporales del SDM. . . . .	65
2.2. Representación gráfica de los efectos temporales del SLMSTFE. . . . .	71
3.1. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años para los años 1990 y 2012 en Europa. . . . .	99
3.2. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años para los años 1990 y 2012 en Europa. . . . .	100

C.1. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1990. . . . .	140
C.2. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1990. . . . .	140
C.3. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1991. . . . .	141
C.4. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1991. . . . .	141
C.5. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1992. . . . .	142
C.6. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1992. . . . .	142
C.7. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1993. . . . .	143
C.8. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1993. . . . .	143
C.9. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1994. . . . .	144
C.10. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1994. . . . .	144
C.11. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1995. . . . .	145
C.12. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1995. . . . .	145
C.13. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1996. . . . .	146
C.14. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1996. . . . .	146
C.15. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1997. . . . .	147

C.16. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1997. . . . .	147
C.17. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1998. . . . .	148
C.18. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1998. . . . .	148
C.19. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1999. . . . .	149
C.20. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1999. . . . .	149
C.21. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2000. . . . .	150
C.22. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2000. . . . .	150
C.23. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2001. . . . .	151
C.24. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2001. . . . .	151
C.25. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2002. . . . .	152
C.26. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2002. . . . .	152
C.27. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2003. . . . .	153
C.28. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2003. . . . .	153
C.29. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2004. . . . .	154
C.30. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2004. . . . .	154

C.31. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2005. . . . .	155
C.32. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2005. . . . .	155
C.33. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2006. . . . .	156
C.34. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2006. . . . .	156
C.35. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2007. . . . .	157
C.36. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2007. . . . .	157
C.37. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2008. . . . .	158
C.38. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2008. . . . .	158
C.39. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2009. . . . .	159
C.40. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2009. . . . .	159
C.41. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2010. . . . .	160
C.42. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2010. . . . .	160
C.43. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2011. . . . .	161
C.44. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2011. . . . .	161
C.45. Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2012. . . . .	162

C.46. Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2012. . . . .	162
D.1. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1990. . . . .	164
D.2. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1990. . . . .	164
D.3. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1991. . . . .	165
D.4. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1991. . . . .	165
D.5. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1992. . . . .	166
D.6. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1992. . . . .	166
D.7. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1993. . . . .	167
D.8. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1993. . . . .	167
D.9. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1994. . . . .	168
D.10. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1994. . . . .	168
D.11. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1995. . . . .	169
D.12. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1995. . . . .	169
D.13. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1996. . . . .	170
D.14. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1996. . . . .	170

D.15.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1997. . . . .	171
D.16.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1997. . . . .	171
D.17.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1998. . . . .	172
D.18.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1998. . . . .	172
D.19.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1999. . . . .	173
D.20.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1999. . . . .	173
D.21.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2000. . . . .	174
D.22.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2000. . . . .	174
D.23.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2001. . . . .	175
D.24.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2001. . . . .	175
D.25.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2002. . . . .	176
D.26.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2002. . . . .	176
D.27.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2003. . . . .	177
D.28.Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2003. . . . .	177
D.29.Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2004. . . . .	178

D.30. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2004. . . . .	178
D.31. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2005. . . . .	179
D.32. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2005. . . . .	179
D.33. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2006. . . . .	180
D.34. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2006. . . . .	180
D.35. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2007. . . . .	181
D.36. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2007. . . . .	181
D.37. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2008. . . . .	182
D.38. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2008. . . . .	182
D.39. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2009. . . . .	183
D.40. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2009. . . . .	183
D.41. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2010. . . . .	184
D.42. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2010. . . . .	184
D.43. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2011. . . . .	185
D.44. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2011. . . . .	185

D.45. Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2012. . . . .	186
D.46. Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2012. . . . .	186
E.1. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1990. . . . .	188
E.2. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1990. . . . .	188
E.3. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1991. . . . .	189
E.4. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1991. . . . .	189
E.5. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1992. . . . .	190
E.6. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1992. . . . .	190
E.7. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1993. . . . .	191
E.8. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1993. . . . .	191
E.9. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1994. . . . .	192
E.10. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1994. . . . .	192
E.11. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1995. . . . .	193
E.12. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1995. . . . .	193
E.13. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1996. . . . .	194



E.14. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1996. . . . .	194
E.15. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1997. . . . .	195
E.16. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1997. . . . .	195
E.17. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1998. . . . .	196
E.18. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1998. . . . .	196
E.19. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1999. . . . .	197
E.20. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1999. . . . .	197
E.21. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2000. . . . .	198
E.22. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2000. . . . .	198
E.23. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2001. . . . .	199
E.24. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2001. . . . .	199
E.25. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2002. . . . .	200
E.26. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2002. . . . .	200
E.27. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2003. . . . .	201
E.28. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2003. . . . .	201

E.29. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2004. . . . .	202
E.30. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2004. . . . .	202
E.31. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2005. . . . .	203
E.32. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2005. . . . .	203
E.33. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2006. . . . .	204
E.34. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2006. . . . .	204
E.35. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2007. . . . .	205
E.36. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2007. . . . .	205
E.37. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2008. . . . .	206
E.38. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2008. . . . .	206
E.39. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2009. . . . .	207
E.40. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2009. . . . .	207
E.41. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2010. . . . .	208
E.42. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2010. . . . .	208
E.43. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2011. . . . .	209

E.44. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2011. . . . . 209

E.45. Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2012. . . . . 210

E.46. Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2012. . . . . 210



# Índice de tablas

1.1. VIF de covariables . . . . .	13
1.2. Clasificaciones LISA para cada país y sus vecinos. . . . .	17
1.3. Valores del índice de Moran global y p-valores asociados al SMR. . . . .	28
1.4. Resultado del modelo SLMSTFE con 4 covariables . . . . .	31
1.5. Resultado del modelo SLMSTFE con 3 covariables . . . . .	32
1.6. Estimación de los efectos fijos espaciales del modelo SLMSTFE con 3 covariables . . . . .	33
1.7. Estimación de los efectos fijos temporales del modelo SLMSTFE con 3 covariables . . . . .	34
1.8. Resultado de la prueba de LM para efectos espaciales, efectos temporales y efectos espaciales y temporales. . . . .	35
1.9. Valores del índice de Moran global y p-valores asociados a los residuos del SLMSTFE. . . . .	37
2.1. Efectos directos e indirectos para los diferentes modelos espa- ciales econométricos . . . . .	51

2.2. Estimación de modelos no espaciales de datos de panel en Matlab y R. . . . .	58
2.3. Resultado de la prueba LR en Matlab . . . . .	59
2.4. Resultado de la prueba LM para el efecto espacial, temporal y ambos en R . . . . .	60
2.5. Resultado del test de Hausman en Matlab y R . . . . .	61
2.6. Estimación del modelo SDM con efecto fijo espacial y temporal en Matlab. . . . .	62
2.7. Estimación de los efectos espaciales del SDM en Matlab . . . . .	63
2.8. Estimación de los efectos temporales del SDM en Matlab . . . . .	64
2.9. Estimaciones de efectos directos e indirectos basados en los coeficientes del SDM . . . . .	67
2.10. Resultado del SLMSTFE en R . . . . .	68
2.11. Estimación de los efectos espaciales del SLMSTFE en R . . . . .	69
2.12. Estimación de los efectos temporales del SLMSTFE en R . . . . .	70
2.13. Estimaciones de efectos directos e indirectos basados en los coeficientes del SLMSTFE . . . . .	73
3.1. Comportamiento del CMF en los países europeos para hombres entre 0 y 14 años durante el período 1990-2012 . . . . .	91
3.2. Comportamiento del CMF en los países europeos para hombres entre 15 y 64 años durante el período 1990-2012 . . . . .	92
3.3. Comportamiento del CMF en los países de Europa para hombres entre 65 y 110+ edades durante el período 1990-2012 . . . . .	93
3.4. Comportamiento del CMF en países europeos para mujeres entre 0 y 14 años durante el período 1990-2012 . . . . .	94
3.5. Comportamiento del CMF en los países europeos para mujeres entre 15 y 64 años durante el período 1990-2012 . . . . .	95

3.6. Comportamiento del CMF en los países europeos para las mujeres entre 65 y 110+ edades durante el período 1990-2012 . . .	96
3.7. Valores del índice de Moran global y p-valores asociados para los hombres . . . . .	97
3.8. Valores del índice de Moran global y p-valores asociados para las mujeres . . . . .	98
3.9. Valores del la prueba $\chi^2$ . . . . .	100





# Introducción

La mortalidad se puede definir como la cantidad de personas que mueren en un determinado lugar durante un período de tiempo en relación con el total de la población. En concreto, Europa es un continente con una gran variabilidad en su mortalidad, especialmente en dos grandes grupos de países: los países de Europa oriental o también llamados países del este de Europa y los países de Europa occidental o también llamados países del oeste de Europa. Esta diferencia entre Europa oriental y Europa occidental, se produjo principalmente después del colapso de la Unión Soviética (siglo XX) y, cada vez es mayor (Vågerö 2010). Por lo tanto, la mortalidad en Europa no sólo ha variado con el tiempo, sino que también ha variado en función del país, ya que no todos tienen las mismas condiciones de salud y económicas (EUROSTAT 2009).

Por otra parte variables socioeconómicas como el sexo, la edad, la raza y otras, dependiendo de la unidad geográfica que se considere, pueden influir en el riesgo de enfermedades y por tanto en la mortalidad. Las diferencias observadas en la mortalidad se confunden por estas variables (Rezaeian y col. 2007) por lo que para poder comparar tasas brutas de mortalidad entre diferentes áreas geográficas será necesario estandarizar dichas tasas. Existen dos métodos de estandarización: directos e indirectos. El método directo produce la Cifra Comparativa de Mortalidad (CMF) y el método indirecto el Ratio de Mortalidad Estandarizado (SMR) (Fleiss, Levin y Paik 2013). El CMF fue propuesto por General Register Office (1884) en 1884. Este ratio es una estimación del número esperado de muertes en la población de referencia si las tasas específicas de edad fueran las mismas que las que se han observado en la población estudiada (Rezaeian y col. 2007). El ratio se obtiene dividiendo el número esperado de

muertes en la población de referencia entre el número observado de muertes en la población de referencia durante el mismo período de tiempo (Breslow y Day 1987; Julious, Nicholl y George 2001).

El SMR se calcula dividiendo el número observado de muertes dentro de la población estudiada entre el número esperado de muertes en la población estudiada, asumiendo que las tasas de mortalidad específicas por edad fueran las de la población estándar o de referencia (Hinde 1998).

El conocimiento de que la mortalidad se concentra en determinadas áreas geográficas es de vital importancia. Por ejemplo, en el ámbito de las políticas públicas ayuda a prevenir, tratar o mejorar la mortalidad así como una distribución eficiente de recursos. En el ámbito actuarial ayuda a los actuarios en el diseño de las pensiones y seguros de vida. Estas concentraciones espaciales se producen por la existencia de autocorrelación o dependencia espacial, la cual implica que la mortalidad de áreas geográficamente cercanas estará más relacionada que aquella de áreas geográficamente distantes. Esto es debido a que países vecinos pueden tener características sociales, económicas y culturales similares. La detección de la dependencia espacial, se logra mediante el uso de la estadística espacial.

La estadística espacial proporciona medidas o estadísticos de autocorrelación espacial, los cuales ofrecen información resumida muy útil sobre la distribución espacial de los datos. En concreto, los estadísticos que hemos utilizado en esta tesis tienen en cuenta las relaciones de vecindad entre las unidades geográficas. Para detectar una concentración global de mortalidad utilizamos el estadístico “índice de Moran global” desarrollado por Moran (1950a). Éste es una medida resumen de la intensidad de la autocorrelación de las unidades geográficas consideradas. Mientras que para identificar grupos o clusters de unidades geográficas a nivel local se utilizó el “índice de Moran local” introducido por Anselin (1995). Éste detecta clusters de unidades espaciales con una mortalidad similar para así poder construir mapas. Este índice es la versión local del índice de Moran global. Las técnicas descriptivas anteriores permiten estudiar la autocorrelación espacial de una forma estática, ya que cada una de ellas, se obtienen para cada unidad temporal. Para estudiar una evolución espacio-temporal conjunta de la mortalidad se utilizó la técnica de cadenas de Markov espaciales propuesta por Rey (2001) y Rey (2014).

Si las técnicas exploratorias anteriores confirman la dependencia espacial en los datos a lo largo del tiempo, puede implementarse un modelo espacial de datos de panel que modelice dicha autocorrelación espacio-temporal. Estos modelos formulan y prueban hipótesis de comportamiento más complicadas,

---

modelizando efectos que no pueden ser tratados usando estudios transversales o longitudinales (Elhorst 2014). Además, como aprovechan la dimensión espacial y temporal de los datos del panel estiman de forma muy eficiente los parámetros del modelo (Baltagi 2008; Elhorst 2014).

Aunque somos conocedores del gran papel que juega la investigación en la salud humana centrándose sobre todo en las personas y en el tiempo, ésta en muchos casos, no tiene en cuenta de la dimensión espacial de los datos a lo largo del tiempo (Rezaeian y col. 2007). Esto se debe, principalmente, a la escasez de softwares adecuados para estudiar datos con dimensión espacial y temporal, es decir, datos de panel. Aunque existen paquetes para estimar modelos espaciales transversales en R, Stata y Matlab, son escasos los paquetes que estiman modelos espaciales de datos de panel (Millo y Piras 2012).

Por ello los objetivos de esta tesis son los siguientes:

- Mostrar cómo estandarizar la tasa bruta de mortalidad para poder realizar comparaciones entre países.
- Presentación y aplicación de una metodología espacio-temporal basada en datos de panel para llevar a cabo la identificación de grupos o clusters significativos de países europeos con mortalidad similar a lo largo del tiempo.
- Propuesta y adaptación una metodología espacio-temporal para seleccionar el mejor modelo espacial de datos de panel con el fin de modelizar de forma correcta el efecto espacial y el temporal.

Esta metodología estadística de reciente creación, se encuentra en diversos campos de investigación como la epidemiología, criminología, geología, ecología, biología, astronomía y muchas otras, pero hasta ahora, no se ha aplicado en el campo actuarial.

La metodología estadística detallada a nivel teórico se aplica a datos de mortalidad de 26 países de la Unión Europea para un rango de edad comprendido entre 0 a 110+ y un horizonte temporal de más de 15 años. Es de nuestro interés aplicar y mostrar esta metodología en un software estadístico libre R y, por tanto, al alcance de todos.

Con esta serie de objetivos, hemos organizado nuestro trabajo de la siguiente forma:

**Capítulo 1.-** Está dedicado a detallar el método más utilizado para estandarizar la mortalidad de Europa y así poder realizar comparaciones entre países. A continuación muestra la metodología espacio-temporal utilizada para detectar clusters espaciales significativos de países europeos con una mortalidad similar. Esta metodología tiene en cuenta las relaciones de vecindad entre los países de Europa. Gracias a ella, se comprueba que las diferencias en la mortalidad a lo largo del tiempo son significativas. Confirmada la autocorrelación espacial en los países europeos durante el período 1990-2012, se mostró el modelo estadístico finalmente implementado. Este modelo, controla la dependencia espacial de los países europeos a través del tiempo. Los coeficientes del modelo se interpretaron y su rendimiento se evaluó utilizando dos medidas de bondad de ajuste: la varianza residual y el coeficiente de determinación. El capítulo acaba mostrando los principales resultados y conclusiones de aplicar dicha metodología a datos de mortalidad de 26 países europeos durante el período de tiempo 1990-2009.

**Capítulo 2.-** Se encarga de mostrar la metodología estadística propuesta por Elhorst (2011) para seleccionar el mejor modelo espacial con datos de panel utilizando el software estadístico Matlab. Las rutinas utilizadas se muestran en el Anexo B. Para ello, el capítulo empieza detallando los modelos espaciales de datos de panel más comúnmente utilizados en la investigación. Adicionalmente, dicha metodología se implementa en R para su posterior comparación con Matlab, adjuntando su código en el Anexo A. Igual que en el Capítulo 1 se aplicaron los datos de mortalidad de 26 países europeos durante el período de tiempo 1990-2009. El capítulo acaba validando los modelos finales obtenidos con ambos softwares mediante dos medidas de bondad de ajuste: el coeficiente de determinación y la varianza residual. Los coeficientes de los modelos finales se interpretaron incluyendo los efectos directos e indirectos (spillover espacial).

**Capítulo 3.-** Está dedicado a detallar el método utilizado para estandarizar la mortalidad de Europa en función de los datos disponibles, de forma que se plantea la comparación por sexos y las conclusiones para diferentes grupos de edad. A continuación muestra la metodología espacio-temporal utilizada para detectar clusters espaciales significativos de países europeos por edad y sexo. Esta metodología, tiene en cuenta las relaciones de vecindad entre países. Además, se estudió la interacción espacio-tiempo en los datos utilizando cadenas de Markov, permitiendo estudiar la autocorrelación espacial de una manera dinámica. El capítulo finaliza mostrando los principales resultados y conclusiones de aplicar dicha metodología a

---

los datos de mortalidad de 26 países europeos por sexo y edad durante el período de tiempo 1990-2012. Los datos se descargaron utilizando el paquete `HMDHFDplus` de R y no el habitual `demography`. De esta forma, los se descargan en un objeto `data.frame` lo cual facilita el tratamiento de éstos. Además, las muertes observadas se han podido obtener directamente.



## Capítulo 1

# Evaluar las diferencias de mortalidad en Europa

*En las últimas décadas, la esperanza de vida ha aumentado en todo el continente europeo, y especialmente, en los países del oeste de Europa. Sin embargo, este estudio detectó que la mortalidad observada es más alta que la esperada en los países del este de Europa, ampliando la brecha entre estos países y los del oeste. El objetivo principal de este trabajo es estudiar la dependencia espacial de clusters significativos a través de un modelo espacial de datos de panel. Aunque muchos estudios abordan la disminución de la mortalidad en Europa, ninguno de ellos utiliza una metodología espacial para detectar clusters significativos de países con mortalidad similar, implementando a su vez un modelo espacial que controle la dependencia espacial de los países europeos a través del tiempo. Así pues, este estudio determina áreas de comportamiento diferenciadas y controla la interacción espacial entre países europeos a lo largo del tiempo aplicando un modelo espacial de datos de panel. La metodología utilizada tiene en cuenta las relaciones de vecindad entre los países de Europa a lo largo del tiempo. El rendimiento del modelo se evaluó utilizando dos medidas de bondad de ajuste, la varianza residual y el coeficiente de determinación. Esta metodología estadística se aplicó a 26 países europeos durante el período 1990-2009. El software estadístico libre que se utilizó para realizar todos los análisis fue R.*

## 1.1 Introducción

Aunque, en las últimas décadas, la mortalidad ha disminuido en todos los países de la Unión Europea, todavía se observan diferencias considerables en los niveles de mortalidad entre países, especialmente entre países occidentales (también llamados países del oeste de Europa) y países orientales (países del este de Europa). Los países europeos han sufrido una situación de divergencia entre Europa oriental y Europa occidental, especialmente después del colapso de la Unión Soviética. La división de salud entre el este y el oeste, se debió en primer lugar al choque entre dos áreas durante el siglo XX: la económica y la política; y en segundo lugar al colapso de la Unión Soviética (Vågerö 2010). Así, la brecha en Europa empezó en el siglo XX, en concreto, a finales del año 1980.

Entre 1970 y 1984 la mortalidad de los países comunistas de Europa central y del este (CEE), así como la República Checa, Hungría, Polonia y Eslovaquia y los países bálticos Estonia, Letonia y Lituania sufrieron un lento crecimiento. La campaña contra el alcohol introducida por Michael Gorbachev durante el período 1984-1987 en Rusia, produjo un aumento en la esperanza de vida. El impacto fue más pronunciado en la reducción de la mortalidad debida a lesiones, envenenamiento y algunas enfermedades cardiovasculares entre los hombres adultos (Bobadilla, Costello, Mitchell y col. 1997). En 1989-1991 con el colapso del muro de Berlín, los países de la CEE experimentaron una disminución de la mortalidad en respuesta al cambio político y económico. En contra, Rusia, así como las repúblicas más pobres de la antigua Unión Soviética, incluidos los Estados bálticos, sufrieron un aumento de la mortalidad. A finales de 2008, el Ministerio de Salud de Rusia propuso un conjunto de objetivos ambiciosos para mejorar la salud de la población (Leon 2011). El colapso del sistema provocó en 1989 una crisis de salud. Esto afectó principalmente a los países comunistas, impidiendo su progreso mientras que los países de Europa occidental comenzaron a progresar debido a los nuevos avances en el cuidado de la salud, específicamente en el tratamiento de las enfermedades cardiovasculares (Meslé y Vallin 2002).

Europa es un continente con países que han progresado juntos pero de una manera muy diferente, lo que ha llevado a la existencia de una gran variabilidad entre sus tasas de mortalidad, particularmente entre los países orientales y occidentales (Meslé y Vallin 2002). La Figura 1.1 muestra la mortalidad de Europa en 1990, 2000 y 2009 cuantificada mediante el Ratio de Mortalidad Estandarizado (SMR) y fraccionada según sus quintiles que se muestran en la leyenda. Este ratio se detallará en la Sección 1.2.2. En la Figura 1.1 se observa



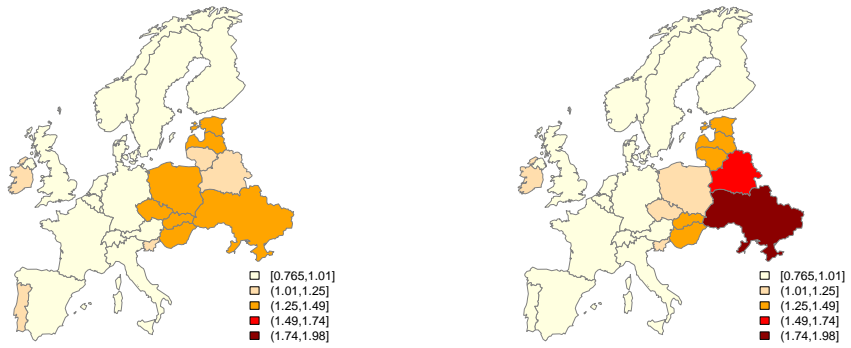
que el SMR en los países del este es más alto que en los países del oeste y, además, ha ido aumentando con el tiempo. Por lo tanto, la mortalidad no sólo ha variado con el tiempo, sino que también ha variado en función del país, ya que no todos tienen las mismas condiciones de salud y económicas (EUROSTAT 2009). Por ello, este trabajo está motivado por el interés en las desigualdades entre los sistemas de salud en diferentes países europeos (Spinakis y col. 2011).

La econometría espacial es un campo de la econometría que trata los efectos de la interacción espacial entre unidades geográficas. En la última década, la literatura relacionada con la econometría espacial se ha centrado en la especificación y estimación de relaciones econométricas basadas en datos de panel (Elhorst 2014). Los datos del panel son datos que contienen varias unidades geográficas seguidas a lo largo del tiempo.

Generalmente, los datos del panel son más informativos, contienen más variación y, a menudo, menos colinealidad entre las variables. Los estudios de series temporales contienen mucha multicolinealidad, mientras que si se trabaja con un panel de datos esto es menos probable, ya que la dimensión de la sección transversal añade mucha variabilidad, agregando más información sobre las variables. El uso de datos de panel da como resultado una mayor disponibilidad de grados de libertad, y por lo tanto aumenta la eficiencia en la estimación de parámetros en un modelo estadístico (Baltagi 2008; Elhorst 2014).


El objetivo principal de este estudio es determinar zonas de comportamiento diferenciadas y estudiar la interacción espacial entre los países europeos a lo largo del tiempo aplicando una metodología espacio-temporal. Esta metodología tiene en cuenta las relaciones de vecindad entre los países europeos a lo largo del tiempo. En primer lugar, se detectaron agrupaciones significativas de países europeos con mortalidad similar y en segundo lugar se aplicó un modelo espacial de datos de panel para modelar la dependencia de las unidades geográficas a lo largo del tiempo. El rendimiento del modelo se evaluó utilizando la conocida medida de bondad de ajuste denominada varianza residual ( $\sigma^2$ ) y coeficiente de determinación ( $R^2$ ).

Este capítulo está estructurado de la siguiente manera: la Sección 1.2 empieza describiendo la base de datos de los países seleccionados. La sección continúa detallando la metodología espacial que se utilizó para identificar grupos de países con mortalidad similar y termina con una exposición del modelo de panel espacial implementado. En la Sección 1.3, se muestran los principales resultados de aplicar el modelo espacial a la base de datos. Finalmente, la Sección 1.4 presenta las principales conclusiones obtenidas en este estudio.



(a) 1990

(b) 2000



(c) 2009

**Figura 1.1:** Ratio de Mortalidad Estandarizada en Europa

## 1.2 Materiales y Métodos

### 1.2.1 Datos

Este estudio utiliza datos de mortalidad de países europeos para el período comprendido entre 1990 y 2009 y para el rango de edad de 0 a 110+, considerando un país como unidad de análisis. Los datos fueron descargados de la Human Mortality Database (2014) (HMD) para un total de 26 países europeos: Alemania, Austria, Bélgica, Bielorrusia, Dinamarca, Eslovaquia, Eslovenia, España, Estonia, Finlandia, Francia, Hungría, Irlanda, Italia, Letonia, Lituania, Luxemburgo, Noruega, Países Bajos, Polonia, Portugal, Reino Unido, República Checa, Suecia, Suiza y Ucrania. Se consideraron estos 26 países porque, todos ellos, tenían información común en la base de datos para el intervalo de tiempo máximo 1990-2009 y para el rango de edad de 0 a 110+.

Los datos se descargaron de la HMD utilizando el paquete de R llamado *demography* de Hyndman y col. (2014) con la función `hmd.mx`. Los argumentos de esta función son:

- Código identificativo del país. Para saber los códigos de todos los países de la HMD escribir y ejecutar `getHMDcountries()`.
- Nombre de usuario en la HMD. Para ello, el usuario debe registrarse en la HMD en el siguiente link: <http://www.mortality.org/mp/auth.pl>
- Contraseña de usuario en la HMD.
- Etiqueta con el nombre del país.

La salida de la función devuelve un objeto lista con 6 elementos que son:

- Año.- Vector de años.
- Edad.- Vector de edades.
- Tasa.- Una lista que contiene matrices de tasas con un grupo de edad por fila y una columna por año.
- Población.- Una lista de la misma forma que tasa pero que contiene números de población en lugar de tasas.
- Tipo de objeto.- Mortalidad (en nuestro caso), fertilidad o migración.

- Etiqueta.

Con el objetivo de explicar el comportamiento de la mortalidad en función de variables demográficas y económicas, se recopiló información sobre cinco variables para estos 26 países y 20 años en la web The World Bank Database (2015). Estas variables fueron: crecimiento de la población, producto interior bruto (PIB), tasa de natalidad, tasa de actividad y consumo de energía del sector vial.

- *Crecimiento de la población (% anual)*.- La tasa de crecimiento anual de la población para el año  $t$  es la tasa exponencial de crecimiento de la población de mediados del año  $t-1$  al año  $t$ , expresada como porcentaje.
- *Producto Interior Bruto (% anual)*.- Tasa anual de crecimiento porcentual del PIB a precios de mercado basada en la moneda local constante. El PIB es la suma del valor añadido bruto de todos los productores residentes en la economía más los impuestos sobre los productos y menos las subvenciones no incluidas en el valor de los productos. Se calcula sin hacer deducciones por depreciación de activos manufacturados o por agotamiento y degradación de recursos naturales. Esta variable contiene datos faltantes, a diferencia del resto. Para imputar dichos datos, se utilizó la función `knnImputation` del paquete `DMwR` de Torgo (2010). Esta función calcula los valores faltantes con un promedio local ponderado.
- *Tasa bruta de natalidad (por 1.000 personas)*.- La tasa bruta de natalidad indica el número de nacidos vivos que se producen en un año por cada 1.000 habitantes.
- *Tasa de actividad (% de la población total de edades  $\geq 15$ )*.- La tasa de actividad es la proporción de la población de 15 años o más, que es económicamente activa; todas las personas que suministran mano de obra para la producción de bienes y servicios durante un período determinado.
- *Consumo de energía del sector vial (% del consumo total de energía)*.- El consumo de energía en el sector vial es la proporción de la energía total utilizada en el sector vial, incluyendo productos petrolíferos, gas natural, electricidad y combustibles renovables y residuos.

Con el fin de evitar la multicolinealidad en las covariables descritas anteriormente, se utilizó el Factor de Inflación de la Varianza (VIF). Esta medida es menor para las variables que no producen multicolinealidad. Finalmente, se seleccionaron las covariables con valores de VIF menor a 2. La Tabla 1.1 muestra

**Tabla 1.1:** VIF de covariables

Variable	VIF
Crecimiento de la población	2.0419
Tasa bruta de natalidad	1.5860
Tasa de actividad	1.1738
Consumo de energía vial	1.5619
Producto Interior Bruto	1.0393

estas variables: PIB, tasa de actividad, consumo de energía en el sector vial y tasa de natalidad.

Los análisis estadísticos se realizaron utilizando el software R Core Team (2015) junto con algunos paquetes: **demography** (Hyndman y col. 2014), **maptools** (Bivand y Lewin-Koh 2016; Charpentier 2014), **spdep** (Bivand 2012; Charpentier 2014), **GeoXp** (Laurent, Ruiz-Gazen y Thomas-Agnan 2012), **rgdal** (Bivand, Keitt y Rowlingson 2015), **Gmisc** (Gordon 2016), **RColorBrewer** (Neuwirth 2014), **splm** (Millo y Piras 2012), **plm** (Croissant y Millo 2008) y **DMwR** (Torgo 2010).

### *1.2.2 Metodología espacio-temporal para detectar clusters de países europeos con mortalidad similar*

En esta sección se describirá los estadísticos utilizados para cuantificar la mortalidad y detectar grupos de países europeos con mortalidad similar.

#### *Ratio de Mortalidad Estandarizado (SMR)*

La cuantificación de la mortalidad es importante para determinar los niveles epidemiológicos, demográficos y de desarrollo de un país. La mortalidad está influenciada por factores tales como enfermedades de carácter aleatorio o desastres naturales, por lo que la mortalidad es variable en el tiempo, es decir, no permanece uniforme. Los profesionales de la salud pública se enfrentan constantemente a la comparación de la mortalidad entre diferentes áreas geográficas. No hay problema en comparar las tasas de mortalidad si las poblaciones se distribuyen de manera similar con respecto a otros factores como la edad, la raza, la clase social, etc. . . , pero en realidad esto no sucede. Al comparar las tasas de mortalidad entre diferentes áreas geográficas, estas tasas están influenciadas por la proporción de individuos en cada grupo de edad de

cada área geográfica. Para solucionar este problema, se desarrollaron métodos de estandarización. La estandarización permite comparaciones de la mortalidad entre diferentes áreas geográficas eliminando los efectos que producen los diferentes tamaños en los subgrupos de la población. Hay dos métodos de estandarización: directo e indirecto (Fleiss, Levin y Paik 2013).

El Ratio de Mortalidad Estandarizado (SMR) es el índice más conocido y utilizado, compara las muertes observadas y las esperadas, ambas medidas en el mismo momento del tiempo. El SMR se define como el número de muertes que se esperarían en una población estudiada si las tasas de mortalidad específicas por edad fueran las de la población estándar (Hinde 1998). Su cálculo se expresa como,

$$SMR_{i,t} = \frac{O_{i,t}}{E_{i,t}} \quad \text{para } i \in \{1, \dots, N\} \quad \text{y } t \in \{1, \dots, T\} \quad (1.1)$$

donde,

- $i$  es el país, siendo  $N$  es el número total de países europeos;
- $t$  es el año, donde  $T$  es el número total de años;
- $O_{i,t}$  representa el número de muertes observadas en cada país  $i$  en el año  $t$ ;
- $E_{i,t}$  corresponde al número de muertes esperadas en cada país  $i$  en el año  $t$  bajo la hipótesis de que cada país tiene la misma mortalidad que el conjunto de países de Europa.

Los resultados posibles de este ratio son los siguientes (Hinde 1998):

- $SMR > 1$ .- Un SMR mayor que 1 indica que se detectaron más muertes observadas que esperadas; en este caso hay “exceso de muertes”.
- $SMR < 1$ .- Un SMR menor que 1 indica que se detectaron más muertes esperadas que observadas; en este caso hay “déficit de muertes”.
- $SMR = 1$ .- Un SMR igual a 1 indica que se detectaron el mismo número de muertes esperadas que observadas.

Las muertes observadas no se han podido obtener directamente con la función `hmd.mx`. Por contra, si que disponemos de la tasa de mortalidad y la población.

Por ello, si  $x$  es la edad de la muerte, las muertes observadas se pueden calcular como

$$O_{i,t} = \sum_{x=0}^{110+} m_{x,i,t} P_{x,i,t} \quad \text{para } x \in \{0, \dots, 110+\}$$

donde  $m_{x,i,t}$  representa la tasa de mortalidad y  $P_{x,i,t}$  el tamaño de la población estudiada a la edad  $x$ , país  $i$  y año  $t$ .

Las muertes esperadas se pueden obtener como,

$$E_{i,t} = \sum_{x=0}^{110+} E_{x,i,t} \quad \text{para } x \in \{0, \dots, 110+\},$$

donde  $E_{x,i,t}$  es,

$$E_{x,i,t} = m_{x,t} P_{x,i,t},$$

y  $m_{x,t}$  es la tasa de mortalidad a la edad  $x$  y año  $t$  en el conjunto de países europeos y se obtiene según la ecuación 1.2

$$m_{x,t} = \frac{\sum_{i=1}^N O_{x,i,t}}{\sum_{i=1}^N P_{x,i,t}} \quad \text{para } i \in \{1, \dots, N\}. \quad (1.2)$$

### *Índice de Moran Global*

El índice de Moran global es una medida resumen que muestra la intensidad de la dependencia espacial de todos los países considerados en el estudio, fue propuesto por Moran (1950a) y Moran (1950b). La expresión de este índice es la siguiente,

$$GM_t = \frac{N \sum_i \sum_j W_{ij} (SMR_{i,t} - \overline{SMR}_t)(SMR_{j,t} - \overline{SMR}_t)}{\sum_i \sum_j W_{ij} \sum_i (SMR_{i,t} - \overline{SMR}_t)^2} \quad \text{para } i \in \{1, \dots, N\},$$

$$j \in \{1, \dots, N\} \quad \text{y } i \neq j$$

donde  $\overline{SMR}_t$  es el promedio del SMR en todos los países en el año  $t$  y  $W_{ij}$  es la matriz de pesos espaciales donde  $i$  and  $j$  son dos países diferentes en el conjunto de  $N$  países europeos considerados.

Respecto a  $W_{ij}$ , la exploración de datos espacio-temporales requiere el establecimiento de una estructura de vecindad entre unidades geográficas que represente la configuración del territorio analizado. Las unidades suelen ser divisiones administrativas establecidas en un territorio determinado.

La estructura de vecindad depende de los criterios utilizados para definir el concepto de vecino. En este estudio, dos países se consideran vecinos cuando comparten frontera y vértices comunes, lo que se conoce como criterio reina y fue propuesto por Anselin, Sridharan y Gholston (2007). Además, hemos considerado la estructura de vecindad de primer orden dada la importancia de ésta en los trabajos de Diehl (1992) y Anselin (1995). El primer orden de vecindad sólo tiene en cuenta la influencia de los vecinos y no la influencia de los vecinos de los vecinos (segundo orden) o la influencia de los vecinos de los vecinos de los vecinos (el tercer orden), y así sucesivamente. Para ver otras estructuras de vecindad, ver Cliff y Ord (1973)

Con ello,  $W_{ij}$  puede tomar los siguientes valores:

$$\begin{aligned} W_{ii} &= 0, & \text{para } i = 1, \dots, N; \\ W_{ij} &= \frac{1}{n_i}, & \text{si } j \in V(i), \text{ con } n_i = \#V(i); \\ W_{ij} &= 0, & \text{si } j \notin V(i), \end{aligned}$$

donde  $n_i$  es el número de vecinos de  $i$  y  $V(i)$  el conjunto de vecinos del país  $i$ . De forma que si  $W_{ij} = 0$  los países  $i$  y  $j$  no se consideran vecinos, mientras que si  $W_{ij} \neq 0$  los países  $i$  y  $j$  sí que lo son, con un peso  $1/n_i$ . Los valores de cada fila suman la unidad, porque los pesos  $W_{ij}$  están estandarizados y un país no puede ser vecino de sí mismo dado que  $W_{ii} = 0$ .

Los resultados posibles de este índice son los siguientes:

- $GM_t > 0$ .- Valores positivos de este índice indican una autocorrelación espacial positiva en los países europeos. Esto significa que cuando el SMR de un país aumenta o disminuye, el SMR de sus vecinos también aumenta o disminuye simultáneamente.
- $GM_t < 0$ .- Valores negativos de este índice indican una autocorrelación espacial negativa en los países europeos. Esto significa que cuando el



**Tabla 1.2:** Clasificaciones LISA para cada país y sus vecinos.

Clase	SMR de un país	$\overline{SMR}$ de los vecinos
HH	Por encima de la media	Por encima de la media
HL	Por encima de la media	Por debajo de la media
LH	Por debajo de la media	Por encima de la media
LL	Por debajo de la media	Por debajo de la media

SMR de un país aumenta o disminuye, el SMR de sus vecinos disminuye o aumenta simultáneamente.

- $GM_t = 0$ .- Valores del índice cercanos a cero indican la ausencia de autocorrelación espacial entre los 26 países europeos.

### *Índice de Moran Local*

El índice de Moran local es un indicador local de la asociación espacial (LISA), que fue introducido por Anselin (1995). Sus siglas provienen del inglés “Local Indicator of Spatial Association”. Este índice determina si el esquema de correlación espacial detectado en todos los países del estudio también se mantiene localmente. En la notación habitual en este contexto, L indica valores del SMR de un país que son más bajos que la media general y H denota valores del SMR de un país que son más altos que la media general. De la misma manera para los vecinos, L y H denotan, que la media del SMR de los vecinos es más alta o más baja respectivamente que la media general. Por lo tanto, cada observación podría establecerse en una de cuatro categorías (Rey 2001), tal y como se resume en la Tabla 1.2.

La expresión del índice de Moran local es la siguiente,

$$LM_{i,t} = \frac{(SMR_{i,t} - \overline{SMR}_t)}{S^2(SMR_t)} \sum_i \sum_j W_{ij} (SMR_{j,t} - \overline{SMR}_t) \quad \text{para } i \in \{1, \dots, N\},$$

$$j \in \{1, \dots, N\} \quad \text{y } i \neq j$$

donde  $S^2(SMR_t)$  es la varianza del  $SMR_t$  en el año  $t$ .

Cuando el índice de Moran local es significativo, se detectan dos tipos de agrupaciones o clusters:

- $LM_{i,t} > 0$ .- Un índice de Moran local positivo significativo indica Clusters Espaciales de países con valores altos de SMR rodeados de vecinos con valores altos de SMR, denotados por HH o agrupaciones espaciales de países con valores bajos de SMR rodeados de vecinos con también valores bajos de SMR, denotados por LL.
- $LM_{i,t} < 0$ .- Un índice de Moran local negativo significativos indica Clusters Outlier de países con valores bajos de SMR rodeados de vecinos con valores altos de SMR, denotados por LH o agrupaciones outlier de países con valores altos de SMR rodeados de vecinos con valores bajos de SMR, denotados por HL.

Los clusters espaciales, a veces se denominan puntos calientes, pueden identificarse como aquellas ubicaciones o conjuntos de lugares contiguos para los cuales el índice de Moran local es significativo. Este índice se puede utilizar como base para probar la hipótesis nula de que no existe autocorrelación espacial local. Esta prueba indica el grado de agrupación local significativa de valores similares de *SMR* alrededor de un país *i* (Anselin 1995). La suma de todos los índice de Moran local para todos los países es proporcional al índice de Moran global. Para obtener los p-valores del índice de Moran local basados en el número de vecinos de cada país, en este trabajo se utilizó la corrección de Bonferroni. El método de Bonferroni es un test de comparaciones múltiples, el cual fija un nivel de significación  $\alpha$  que se divide entre el número medio de vecinos en cada test. Por tanto, los p-valores ajustados dependen del número de vecinos de un país *i*. Si el p-valor ajustado es menor que 0.05 el país se clasifica como un Cluster Outlier (HL y LH) o un Cluster espacial (HH y LL) (Anselin 1995; Goovaerts y Jacquez 2005).

### 1.2.3 Modelos espaciales de datos de panel

Una vez especificadas las técnicas para estudiar la dependencia espacial de los datos de mortalidad de 26 países europeos durante el periodo de tiempo 1990-2009, el siguiente paso es implementar un modelo estadístico que recoja la dependencia espacial de estos países durante el período de tiempo considerado. A continuación se definen los modelos espaciales comúnmente utilizados en la investigación.

### *Datos de panel*

Los datos del panel son observaciones espaciales (regiones, países, familias, hogares, etc. . . ) seguidas a lo largo del tiempo. Por lo tanto, los datos del panel son una combinación de dos dimensiones: la espacial y la temporal (Wooldridge 2010).

Dependiendo de la amplitud espacial y temporal de los datos, los paneles de datos pueden ser de tres tipos:

- Paneles micro.- Paneles con más observaciones espaciales que observaciones temporales.
- Paneles macro.- Paneles con más observaciones temporales que observaciones espaciales.
- Panel campo aleatorio “random field”.- Son paneles con un amplia dimensión espacial y temporal.

Dependiendo de la existencia o ausencia de datos faltantes, los datos del panel pueden ser de dos tipos,

- Paneles balanceados o completos.- Si todas las unidades estudiadas se observan a lo largo del periodo de estudio.
- Paneles desequilibrados o incompletos.- Si el rango temporal varía entre los individuos. En otras palabras, si existen datos faltantes en el panel considerado.

En concreto, el panel de datos que utilizamos en este estudio es un *Panel micro*, puesto que hay más observaciones espaciales (26 países) que períodos de tiempo (20 años) y un *Panel balanceado* porque no existen datos faltantes, dado que se ha hecho una imputación de valores para el PIB.

*Modelos espaciales de datos de panel: Modelo de retardo espacial con efecto fijo espacial y temporal (SLMSTFE).*

En la actualidad, la econometría espacial está haciendo hincapié en la especificación y estimación de relaciones econométricas basadas en paneles de datos. Este interés puede explicarse por la mayor disponibilidad de una gran cantidad de datos en los que las unidades espaciales se estudian a lo largo del tiempo. Los datos de panel permiten la especificación de hipótesis de comportamiento más complicadas, incluyendo efectos que no pueden ser tratados utilizando

series temporales o datos transversales. Por tanto, un panel de datos ofrece a los investigadores amplias posibilidades de modelización (Elhorst 2014), en comparación con otra tipología de datos.

Un modelo de datos de panel es un modelo de regresión que utiliza la dimensión temporal y espacial de los datos para la estimación de los parámetros de interés. Estos modelos, permiten modelar la heterogeneidad no observada producida tanto por las unidades espaciales estudiadas como por el tiempo. La heterogeneidad no observada la producen las variables de las cuales no tenemos información pero afectan a la variable de interés. Ejemplos de variables no observables que varían para cada unidad transversal y permanecen constantes con el tiempo afectando a la variable dependiente del modelo podrían ser el sexo, la religión o la delincuencia. De manera similar, ejemplos de variables no observables que varían a lo largo del tiempo y permanecen constantes con las unidades transversales afectando a la variable endógena del modelo podrían ser una recesión/expansión económica, guerra mundial, cambios en la legislación o en la política gubernamental. Esta heterogeneidad no observable sólo se puede detectar con modelos de datos de panel (Hsiao 2014). La importancia de controlar esta heterogeneidad, radica en el hecho de que reduce problemas de multicolinealidad entre las variables permitiendo que las estimaciones de los parámetros en los modelos de panel sean más eficientes (Kennedy 2003). Los modelos de datos de panel ofrecen ventajas sobre la regresión de sección transversal o series temporales. Algunas de ellas son:

- Controlan la heterogeneidad no observada producida por unidades espaciales y/o temporales, lo que reduce los problemas de multicolinealidad entre las variables (Kennedy 2003).
- Las unidades geográficas se observan con el tiempo. Este hecho no puede ser estudiado mediante estudios puramente transversales o de series temporales.
- Los datos del panel suelen contener más grados de libertad y más variabilidad que los datos transversales y datos temporales, lo cual favorece la eficiencia de las estimaciones econométricas (Hsiao 2014).

El principal problema de los datos de panel es su recolección, son más complejos que en el caso de datos de corte transversal o series temporales (Arbia y Piras 2005).

Los modelos espaciales de datos de panel tienen en cuenta las relaciones de vecindad entre las unidades geográficas. Éstos pueden utilizarse para explicar

el comportamiento de unidades geográficas, siempre que se encuentren relacionadas entre sí.

El enfoque más simple de analizar un panel de datos es calcular una regresión por mínimos cuadrados ordinarios (OLS), lo que supone obviar la dependencia en las dimensiones del espacio y el tiempo de los datos y suponer que la constante en el modelo es la misma para todas las unidades transversales o espaciales.

Para poder estimar el carácter individual de cada unidad transversal y/o temporal nacen dos modelos: el modelo de efectos fijos y el modelo de efectos aleatorios. El modelo de efectos fijos considera que el efecto tiene un valor fijo para cada unidad transversal y/o temporal, es decir, que las diferencias entre las unidades transversales y/o temporales son constantes. Mientras que el modelo de efectos aleatorios considera que el efecto es una variable aleatoria con una media y una varianza no nula, es decir, que las diferencias entre las unidades transversales y/o temporales son aleatorias (Baltagi 2008). Este último trata las diferencias del efecto aleatorio en la varianza de error y supone que las variables aleatorias y el error del modelo son independientes (Wooldridge 2010; Elhorst 2014).

Elhorst (2014) proporciona una revisión de los modelos de datos de panel espaciales más comúnmente utilizados en la investigación,

- *Modelo de retardo espacial con efecto fijo espacial y temporal (SLMSTFE)*. Sus siglas provienen del inglés “Spatial Lag Model with Spatial and Time Fixed Effects”.
- *Modelo de error espacial con efecto fijo espacial y temporal (SEMSTFE)*. Sus siglas provienen del inglés “Spatial Error Model with Spatial and Time Fixed Effects”.
- *Modelo de retardo espacial con efecto aleatorio (SLMRE)*. Sus siglas provienen del inglés “Spatial Lag Model with Random Effects”.
- *Modelo de error espacial con efecto aleatorio (SEMRE)*. Sus siglas provienen del inglés “Spatial Error Model with Random Effects”.
- *Modelo Durbin espacial (SDM)*. Sus siglas provienen del inglés “Spatial Durbin Model”. Este modelo incluye la correlación espacial en las covariables en los modelos SLMSTFE y SLMRE.

- *Modelo de error espacial Durbin (SDEM)*. Sus siglas provienen del inglés “Spatial Durbin Error Model”. Este modelo incluye la correlación espacial en las covariables en los modelos SEMSTFE y SEMRE.

Acorde con la tipología de nuestros datos, hemos implementado un modelo de retardo espacial con efectos fijos (SLMSTFE). Las razones son las siguientes:

- Efecto fijo espacial y temporal: el modelo de efectos fijos suele ser más apropiado que el modelo de efectos aleatorios, cuando se dispone de datos espacio-temporales de unidades espaciales adyacentes situadas en áreas de estudio ininterrumpidas (Elhorst 2014). Además, intenta modelar el comportamiento de cada país y tiempo individualmente. Este modelo, conocido como “two-ways”, supone que las diferencias entre los países y el tiempo son constantes (Asteriou y Hall 2015). Por esta razón, se incorporan variables dummy espaciales y temporales que modelan la heterogeneidad no observada.
- Retardo espacial: el valor del SMR de un país depende del valor del SMR en otro país adyacente o vecino. Este hecho se confirmará en la Sección 1.3.1.

La formulación común del modelo de efectos fijos, supone que las diferencias entre unidades pueden captarse en el término contante. A continuación, se define matemáticamente el SLMSTFE como,

$$y_{it} = \alpha + \lambda \sum_{j=1}^N W_{ij} y_{jt} + x_{it} \beta + \mu_i + \nu_t + \epsilon_{it}$$

donde:

- $i$  representa los países;
- $t$  representa los años;
- $y_{it}$  representa un vector de dimensión  $NT \times 1$  correspondiente a las observaciones de la variable dependiente para cada país  $i$  y año  $t$ ;

- $W_{ij}$  es la matriz de pesos espaciales o de contigüidad de dimensión  $N \times N$ , donde  $i$  y  $j$  representan dos países cualquiera del total de  $N$  países;
- $x_{it}$  es la matriz de dimensión  $NT \times k$  de observaciones de las variables independientes; donde  $k$  el número de variables independientes;
- $\lambda$  es el parámetro espacial asociado con la variable dependiente;
- $\beta$  vector de dimensión  $k \times 1$  de parámetros desconocidos correspondientes a las observaciones de las variables independientes;
- $\alpha$  es el intercepto del modelo;  
Representa el valor medio de la variable dependiente cuando todas las variables independientes son cero. Este modelo considera una variable dummy para cada unidad espacial  $\mu_i$  y una variable dummy para cada unidad temporal  $\nu_t$  (Elhorst 2003). Estos interceptos ( $\alpha + \mu_i + \nu_t$ ) se estimarán bajo la restricción  $\sum_{i=1}^N \mu_i = 0$  y  $\sum_{t=1}^T \nu_t = 0$  (Baltagi 2008; Hsiao 2014). De esta forma el efecto espacial representa la desviación de la unidad espacial  $i$  respecto del promedio  $\alpha$  y el efecto temporal representa la desviación de la unidad temporal  $t$  respecto del promedio  $\alpha$ . Por ello,  $\alpha$  es el efecto que recoge en términos medios la heterogeneidad no observable producida por variables que permanecen constantes entre países y con el tiempo.
- $\mu_i$  es el efecto espacial fijo que recoge la heterogeneidad no observable producida por variables que cambian a través de los países, pero permanecen constantes en el tiempo. Es un vector dimensión  $N \times 1$ ;
- $\nu_t$  es el efecto fijo temporal que captura la heterogeneidad no observable producida por variables que cambian con el tiempo, pero permanecen constantes entre los países. Es un vector dimensión  $T \times 1$ ;
- $\epsilon_{it}$  es un vector de términos de error independientes e idénticamente distribuidos de dimensión  $NT \times 1$ , el cual recoge la heterogeneidad no observable producida por variables que cambian tanto con el tiempo como entre países. Este vector no está espacialmente autocorrelacionado.

## 1.3 Resultados

En esta sección se muestran los resultados de aplicar la metodología expuesta en la Sección 1.2.2 y 1.2.3.

Para no sobrecargar de información al lector, sólo se muestran las figuras correspondientes al índice de Moran local y global para los años 1990, 2000 y 2009. Los lectores interesados en las figuras de todos los años pueden solicitarlas a los autores.

### *1.3.1 Metodología espacio-temporal para detectar clusters de países europeos con mortalidad similar*

Los resultados de cuantificar la mortalidad en Europa en términos de SMR calculados según la ecuación (1.1) se muestran en esta sección. Para comparar rápidamente la media y la varianza del SMR de cada país europeo entre 1990 y 2009 se elaboró la Figura 1.2. En ella, se muestra la variabilidad del SMR de cada país en el período estudiado. Por ejemplo, Bielorrusia y Ucrania (países del este de Europa) son los países con mayor variabilidad en el SMR, mientras que Bélgica y España (países del oeste de Europa) son dos de los países con menor variabilidad en el SMR.

Los países con valores medios de SMR superiores e inferiores a 1 se identificaron. A continuación se detallan:

- Países con valores de SMR superiores a 1.- Bielorrusia Eslovaquia, Estonia, Hungría, Letonia, Lituania, Polonia, República Checa y Ucrania. En este caso estos países sufren “exceso de muertes” en la población estudiada, debido a que las muertes observadas en estos países son mayores a las muertes que se esperarían si éstos se comportaran de manera similar al conjunto de países europeos. Estos niveles de SMR por encima de 1 se mantuvieron durante el período de estudio, por lo tanto, estos países pueden considerarse no privilegiados.
- Países con valores de SMR inferiores a 1.- Alemania, Austria, Bélgica, España, Finlandia, Francia, Países Bajos, Italia, Luxemburgo, Noruega, Portugal, Reino Unido, Suecia y Suiza. En este caso estos países sufren “déficit de muertes”, ya que las muertes observadas en estos países son inferiores a las muertes que se esperarían si éstos se comportaran como el conjunto de países europeos. Estos niveles de SMR inferiores a 1 se mantuvieron durante el período de estudio, por lo que estos países se consideran privilegiados.






Figura 1.2: Diagrama de cajas del SMR para cada país

- Países con valores SMR de alrededor de 1: Dinamarca, Irlanda y Eslovenia. En estos países las muertes observadas son similares a las que se esperaría si éstos se comportaran como el conjunto de países europeos en el periodo estudiado, por lo que estos países tienen un estatus similar al general.

Por tanto, se confirma que la mortalidad observada es más alta que la esperada en la mayor parte de países del este de Europa a lo largo del tiempo.


La Figura 1.3 muestra los gráficos de dispersión del índice de Moran, donde el valor de SMR para un país se representa en función del SMR promedio de sus vecinos para los años 1990, 2000 y 2009 respectivamente. Todos los gráficos obtenidos para todos los años indican que existe una correlación espacial positiva en el conjunto de países europeos. Los países que se alejan de la tendencia central son los siguientes: Portugal (PT), Estonia (EE), Bielorrusia (BY), Lituania (LT) y Ucrania (UA).

Para confirmar la presencia de autocorrelación espacial a lo largo del tiempo, se contrastó la hipótesis nula  $H_0 : GM_t = 0$ , es decir, que no existe autocorrelación espacial en los 26 países europeos. Para ello se utilizó el paquete `spdep` de R (Bivand 2012). La salida del contraste contiene los siguientes componentes: el valor observado del índice de Moran, el valor esperado, su varianza y el p-valor del test de Moran con el que se corresponde el estadístico:


$$z = \frac{(\text{Valor observado} - \text{Valor esperado})}{\text{desviación estándar}}$$

El resultado de esta prueba se puede contrastar con la prueba de Monte Carlo (MC) (Bivand 2012). El test MC utiliza permutaciones aleatorias del  $SMR_{i,t}$  para la matriz de pesos espaciales, con el objetivo de establecer el valor del índice de Moran global observado en relación con 999 valores simulados. El resultado de este test contiene los siguientes componentes: el valor del índice de Moran observado y el p-valor del test MC. Los resultados de las pruebas de Moran y Monte Carlo para el período considerado se muestran en la Tabla 1.3. Ambas pruebas son sensibles a la forma de la matriz de pesos espaciales. Los p-valores obtenidos para todos los años son significativos (p-valores  $<0.05$ ), lo que indica que existe una dependencia espacial en la mortalidad observada de los 26 países europeos considerados.


Como se indicó en la Sección 1.2.2, valores significativos del índice de Moran local muestran dos tipos de clusters: Clusters Espaciales y Clusters Outlier. Los mapas en la Figura 1.4 muestran agrupaciones espaciales de tipo HH y LL, lo que significa que la mortalidad observada en los países pertenecientes a los diferentes clusters es lo bastante similar como para poder formar esas



(a) 1990



(b) 2000



(c) 2009

**Figura 1.3:** Comportamiento del índice global de Moran en Europa

**Tabla 1.3:** Valores del índice de Moran global y p-valores asociados al SMR.

Año	I.Moran	V. esperado	Varianza	p-valor (M)	p-valor (MC)
1990	0.680	-0.040	0.03	0.000 *	0.001 *
1991	0.738	-0.040	0.03	0.000 *	0.001 *
1992	0.748	-0.040	0.03	0.000 *	0.001 *
1993	0.792	-0.040	0.03	0.000 *	0.001 *
1994	0.818	-0.040	0.03	0.000 *	0.001 *
1995	0.798	-0.040	0.03	0.000 *	0.001 *
1996	0.772	-0.040	0.03	0.000 *	0.001 *
1997	0.774	-0.040	0.03	0.000 *	0.001 *
1998	0.790	-0.040	0.03	0.000 *	0.001 *
1999	0.759	-0.040	0.03	0.000 *	0.001 *
2000	0.746	-0.040	0.03	0.000 *	0.001 *
2001	0.761	-0.040	0.03	0.000 *	0.001 *
2002	0.737	-0.040	0.03	0.000 *	0.001 *
2003	0.733	-0.040	0.03	0.000 *	0.001 *
2004	0.749	-0.040	0.03	0.000 *	0.001 *
2005	0.748	-0.040	0.03	0.000 *	0.001 *
2006	0.769	-0.040	0.03	0.000 *	0.001 *
2007	0.769	-0.040	0.03	0.000 *	0.001 *
2008	0.748	-0.040	0.03	0.000 *	0.001 *
2009	0.759	-0.040	0.03	0.000 *	0.001 *

agrupaciones. Además, se identifica el centro de dichas agrupaciones. El centro del cluster es único y representa el país situado en el centro del cluster. Cuando aparecen varios centros clusters dentro de un único cluster, significa que hay varios clusters pertenecientes a países limítrofes formando un único macrocluster.

En la Figura 1.4 se observan dos clusters significativos de diferentes países europeos hasta el año 2002, identificando en ellos el centro y los vecinos: un cluster de alto SMR compuesto por países del este de Europa (Lituania, Letonia, Estonia, Ucrania, Bielorrusia, Eslovaquia, Hungría y Polonia) y otro cluster de bajo SMR formado por países del oeste de Europa (España, Italia, Francia, Suiza, Alemania, Luxemburgo y Bélgica), según indican los valores significativos del índice de Moran local. Por lo tanto, los valores no significativos del índice de Moran local identifican países que no pertenecen a ningún cluster (República Checa, Reino Unido, Dinamarca, Finlandia, Irlanda, Países Bajos, Noruega, Eslovenia, Portugal, Suecia y Austria).

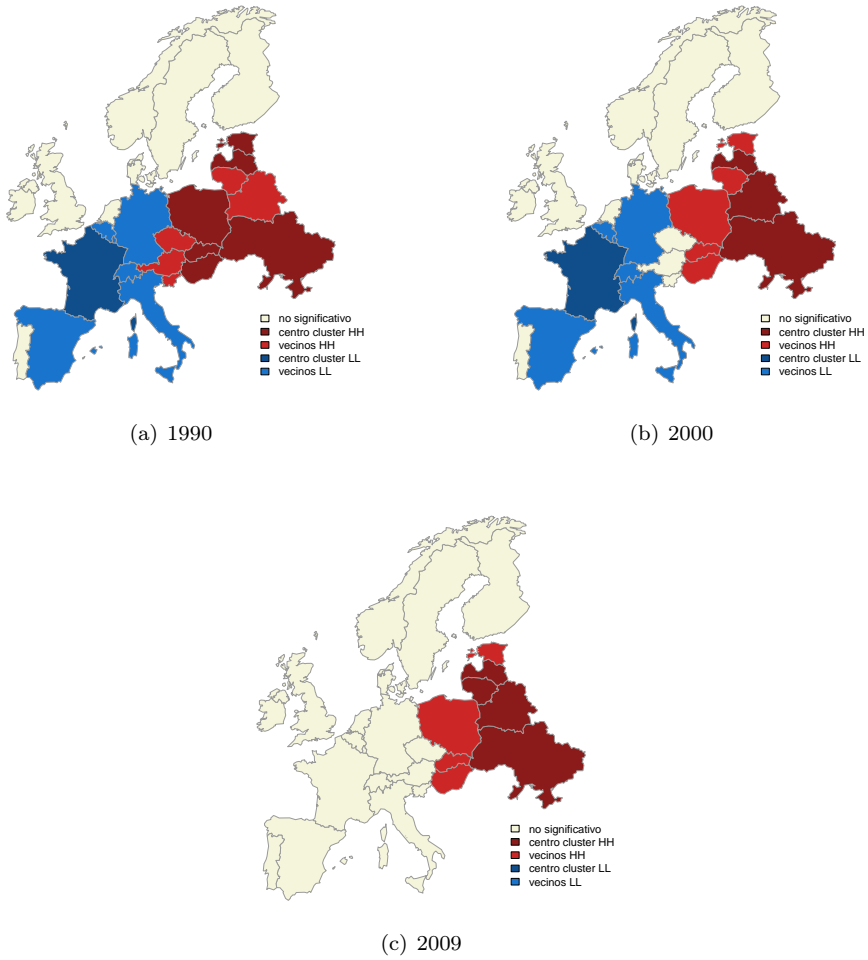
Es importante enfatizar que el centro cluster LL es Francia. Éste, es único y se mantiene constante durante el período 1990-2009. Este cluster LL desaparece a partir de 2002 debido a que la variabilidad de la mortalidad en los países del oeste ha aumentado desde el 2002. Por el contrario, existen varios clusters de tipo HH que forman un único macrocluster HH. Por esta razón en el cluster HH se observan varios centros clusters. Estos centros difieren en el período estudiado, moviéndose del oeste al este de Europa.

Es sorprendente que Austria pertenezca al cluster HH formado por países del este en los años 1990 y 1991. Esto se debe a que Austria, en esos años, compartía frontera con Eslovaquia y Hungría países pertenecientes al centro cluster HH.

### ***1.3.2 Modelo de retardo espacial con efecto fijo espacial y temporal (SLMSTFE)***

Para estimar el modelo SLMSTFE en R se utilizó el paquete `splm` de Millo y Piras (2012). En la función `splm` hay que especificar la fórmula del modelo, la matriz de pesos espaciales, los datos y el tipo de modelo.

Como la variable SMR tiene una fuerte asimetría positiva, para normalizarla la hemos transformado con el logaritmo. Así pues, el logaritmo de SMR es la variable dependiente en el modelo espacial. Las variables independientes consideradas en el modelo son: PIB, tasa de actividad, consumo de energía del sector vial y tasa de natalidad.



**Figura 1.4:** Mapa clusters en Europa

**Tabla 1.4:** Resultado del modelo SLMSTFE con 4 covariables

Parámetros	Estimación	Error estándar	t-valor	p-valor
$\alpha$	0.2810	0.0525	5.3527	0.0000 *
$\lambda$	0.3522	0.0392	8.9933	0.0000 *
$\beta_{PIB}$	0.0042	0.0006	6.9958	0.0000 *
$\beta_{tasa\ actividad}$	-0.0037	0.0009	-3.9394	0.0000 *
$\beta_{consumo\ energia\ vial}$	-0.0042	0.0008	-5.4381	0.0000 *
$\beta_{tasa\ natalidad}$	0.0028	0.0024	1.1919	0.2333

\*p-valores <0.05 son significativos

Los resultados del ajuste del modelo SLMSTFE con las cuatro covariables se muestran en la Tabla 1.4. Ésta incluye los parámetros del modelo, el valor estimado de estos parámetros, el error estándar y los p-valores asociados a cada uno de los parámetros. Se observa que sólo la variable tasa de natalidad no es significativa con un p-valor > 0.05, por lo tanto, se eliminó del modelo (Tabla 1.4).

La Tabla 1.5 muestra el resultado del modelo SLMSTFE ajustado con tres covariables significativas. En este modelo todas las covariables son significativas y tienen el signo esperado. Cabe mencionar el signo positivo de la variable PIB. Este resultado es consistente con el trabajo de EUROSTAT (2013), el cual muestra que aunque las condiciones de salud están relacionadas con el PIB, no dependen totalmente de la producción de riqueza en una economía determinada. Las diferencias entre países también pueden atribuirse a otros factores como la calidad de los servicios de salud, si las organizaciones privadas son públicas, factores ambientales y opciones culturales también afectan los resultados de la salud.

Todas las covariables son significativas, lo que significa que las variables PIB, tasa de actividad y consumo de energía del sector vial son importantes para explicar el logaritmo de SMR. Variaciones en estas tres covariables causan variaciones en el logaritmo de la SMR de un país y, a su vez en el valor del logaritmo del SMR en los países vecinos. Además, la estimación del parámetro espacial ( $\lambda$ ) es positiva (0.3465) y estadísticamente significativa (p-valor = 0). Esto indica que, además de las contribuciones que las covariables realizan al logaritmo del SMR de un país su valor aumenta 34.65 % cuando en promedio el logaritmo de los valores SMR correspondientes al entorno también aumentan.

**Tabla 1.5:** Resultado del modelo SLMSTFE con 3 covariables

Parámetros	Estimación	Error estándar	t-valor	p-valor
$\alpha$	0.2896	0.0523	5.5337	0.0000 *
$\lambda$	0.3465	0.0391	8.8624	0.0000 *
$\beta_{PIB}$	0.0041	0.0006	6.9201	0.0000 *
$\beta_{tasa\ actividad}$	-0.0033	0.0009	-3.7814	0.0002 *
$\beta_{consumo\ energia\ vial}$	-0.0041	0.0008	-5.3165	0.0000 *

\*p-valores <0.05 son significativos

Los resultados de la estimación de los efectos fijos espaciales del modelo SLMSTFE se muestran en la Tabla 1.6. En ella, se muestran los parámetros fijos espaciales del modelo  $\mu_i$ , el valor estimado de estos parámetros, el error estándar y los p-valores asociados a cada uno de los parámetros. El valor de  $\mu_i$  representa la desviación del país  $i$  respecto del intercepto  $\alpha$ . Las estimaciones de los efectos espaciales con un signo negativo pertenecen a los países del oeste de Europa dentro del cluster de bajo SMR. Esto significa que, en estos países, las características no observadas afectan disminuyendo el logaritmo del SMR, en comparación con el promedio  $\alpha$ . Por contra, las estimaciones de los efectos espaciales con un signo positivo pertenecen a los países del este de Europa dentro del cluster de alto SMR. Esto significa que, en estos países, las características no observadas afectan el logaritmo del SMR, en comparación con el promedio  $\alpha$ . La mayoría de los países con efectos espaciales no significativos no forman ningún cluster en la Figura 1.2.

Los resultados de la estimación de los efectos fijos temporales del modelo SLMSTFE se muestran en la Tabla 1.7, la cual incluye los parámetros fijos temporales del modelo  $\nu_t$ , el valor estimado de estos parámetros, el error estándar y los p-valores asociados a cada uno de los parámetros. El valor de  $\nu_t$  representa la desviación del año  $t$  respecto del promedio  $\alpha$ .

Ningún  $\nu_t$  es significativo. Antes de excluir los efectos no significativos del modelo, se debe utilizar la prueba de Multiplicador de Lagrange (LM) de Breusch y Pagan (1980). Esta prueba está implementada en el paquete `plm` de (Croissant y Millo 2008) en R. El objetivo de ésta es contrastar la incorporación de los efectos espaciales o temporales o los efectos espaciales y temporales en el modelo. Si el p-valor es menor que 0.05 la hipótesis nula será rechazada y, por tanto, será necesario incluir los efectos fijos considerados en el modelo. Los



**Tabla 1.6:** Estimación de los efectos fijos espaciales del modelo SLMSTFE con 3 covariables

<b>País</b>	<b>Estimación</b>	<b>Error estándar</b>	<b>t-valor</b>	<b>p-valor</b>
Austria	-0.1368	0.0534	-2.5632	0.0104 *
Bélgica	-0.1182	0.0462	-2.5564	0.0106 *
Bielorrusia	0.2724	0.0529	5.1495	0.0000 *
Suiza	-0.1821	0.0608	-2.9974	0.0027 *
República Checa	0.1167	0.0532	2.1946	0.0282 *
Alemania	-0.1025	0.0523	-1.9614	0.0498 *
Dinamarca	0.0349	0.0592	0.5886	0.5561
Estonia	0.1350	0.0551	2.4527	0.0142 *
España	-0.1978	0.0496	-3.9840	0.0000 *
Finlandia	-0.0673	0.0545	-1.2360	0.2164
Francia	-0.2256	0.0500	-4.5154	0.0000 *
Hungría	0.2044	0.0451	4.5344	0.0000 *
Irlanda	-0.0074	0.0541	-0.1371	0.8909
Italia	-0.2123	0.0452	-4.6915	0.0000 *
Lituania	0.1161	0.0544	2.1342	0.0328 *
Luxemburgo	0.0224	0.0564	0.3972	0.6912
Letonia	0.2544	0.0545	4.6665	0.0000 *
Países Bajos	-0.1217	0.0550	-2.2123	0.0269 *
Noruega	-0.1231	0.0575	-2.1433	0.0321 *
Polonia	0.0522	0.0511	1.0211	0.3072
Portugal	0.0381	0.0554	0.6889	0.4909
Suecia	-0.1727	0.0563	-3.0659	0.0022 *
Eslovenia	0.0213	0.0528	0.4042	0.6860
Eslovaquia	0.1271	0.0541	2.3502	0.0188 *
Ucrania	0.3612	0.0513	7.0437	0.0000 *
Reino Unido	-0.0887	0.0557	-1.5932	0.1111

\*p-valores <0.05 son significativos

**Tabla 1.7:** Estimación de los efectos fijos temporales del modelo SLMSTFE con 3 covariables

Año	Estimación	Error estándar	t-valor	p-valor
1990	-0.0074	0.0532	-0.1392	0.8893
1991	-0.0042	0.0528	-0.0800	0.9363
1992	0.0030	0.0525	0.0565	0.9549
1993	0.0081	0.0519	0.1551	0.8767
1994	-0.0010	0.0522	-0.0190	0.9849
1995	-0.0081	0.0522	-0.1541	0.8775
1996	-0.0134	0.0522	-0.2567	0.7974
1997	-0.0153	0.0528	-0.2900	0.7718
1998	-0.0060	0.0527	-0.1135	0.9096
1999	-0.0038	0.0526	-0.0720	0.9426
2000	-0.0089	0.0532	-0.1673	0.8672
2001	0.0003	0.0526	0.0054	0.9957
2002	0.0033	0.0527	0.0618	0.9507
2003	-0.0025	0.0529	-0.0464	0.9630
2004	-0.0032	0.0534	-0.0591	0.9529
2005	-0.0036	0.0535	-0.0676	0.9461
2006	0.0010	0.0541	0.0178	0.9858
2007	0.0042	0.0544	0.0770	0.9386
2008	0.0130	0.0535	0.2427	0.8083
2009	0.0446	0.0518	0.8615	0.3889

\*p-valores <0.05 son significativos

**Tabla 1.8:** Resultado de la prueba de LM para efectos espaciales, efectos temporales y efectos espaciales y temporales.

LM	$\chi^2$	grados de libertad	p-valor
Efectos espaciales	4168.5	1	0.0000 *
Efectos temporales	2.3718	1	0.1235
Efectos espaciales y temporales	4170.9	2	0.0000 *

\*p-valores <0.05 son significativos

resultados de las prueba LM se muestran en la Tabla 1.8. Ésta incluye el valor del estadístico utilizado en el contraste, los grados de libertad y los p-valores asociados con cada una de las pruebas. La prueba LM concluye que los efectos espaciales y temporales no pueden ser excluidos del modelo porque su p-valor es significativo al 5%.


Adicionalmente, estos  $\nu_t$  se representaron gráficamente en la Figura 1.5. En ella se puede observar que los efectos temporales siguen una tendencia creciente excepto para el período 1994-1998. Esta evolución desfavorable recoge el colapso del sistema soviético. En el año 1994 Rusia tuvo la peor esperanza de vida, así como, Estonia, Letonia y Lituania (países bálticos). Desde 1994 hasta 1998, la esperanza de vida en estos países se hizo más favorable. Esto fue un signo de ajuste a las nuevas circunstancias (Vågerö 2010).

Por último, las medidas de bondad de ajuste utilizadas para validar el modelo fueron la varianza residual  $\sigma^2$  y el coeficiente de determinación ( $R^2$ ). Para obtener la varianza residual del objeto modelo hay que acceder a la parte denominada sigma2 en el output de la función `spml`. Ésta tiene un valor de 0.0014 que es pequeño comparado con la varianza de la variable dependiente. El valor del  $R^2$  es muy alto, 0.97, el cual se ha obtenido a partir del valor de la varianza residual  $\sigma^2$  y de la varianza de la variable dependiente  $\sigma_y^2$  de la siguiente manera:

$$R^2 = 1 - \frac{\sigma^2}{\sigma_y^2} \approx 1 - \frac{S_\epsilon^2}{S_y^2}$$

Ambas medidas indican que es un buen modelo.

Para verificar si el modelo SLMSTFE explica la dependencia espacial de los 26 países europeos detectados por el índice Moran global y local, se estudiaron los residuos del modelo SLMSTFE. Para verificar si el modelo es adecuado, hemos




**Figura 1.5:** Representación gráfica de efectos temporales

**Tabla 1.9:** Valores del índice de Moran global y p-valores asociados a los residuos del SLMSTFE.

Año	I.Moran	V. esperado	Varianza	p-valor (M)	p-valor (MC)
1990	0.131	-0.040	0.025	0.137	0.123
1991	-0.077	-0.040	0.025	0.592	0.582
1992	0.053	-0.040	0.018	0.248	0.243
1993	0.115	-0.040	0.027	0.174	0.200
1994	-0.134	-0.040	0.017	0.767	0.791
1995	-0.057	-0.040	0.018	0.550	0.570
1996	-0.273	-0.040	0.027	0.921	0.928
1997	0.090	-0.040	0.026	0.208	0.198
1998	-0.167	-0.040	0.018	0.824	0.839
1999	0.045	-0.040	0.026	0.300	0.287
2000	-0.041	-0.040	0.023	0.503	0.498
2001	0.073	-0.040	0.027	0.245	0.235
2002	0.186	-0.040	0.027	0.084	0.088
2003	-0.095	-0.040	0.024	0.637	0.627
2004	-0.021	-0.040	0.025	0.453	0.455
2005	0.342	-0.040	0.025	0.008	0.014
2006	0.250	-0.040	0.024	0.031	0.047
2007	-0.111	-0.040	0.028	0.665	0.650
2008	0.045	-0.040	0.027	0.302	0.308
2009	-0.027	-0.040	0.022	0.465	0.466

de ver que los residuos ya no contienen información relevante. La Tabla 1.9 muestra el resultado de aplicar las pruebas de Moran y Monte Carlo a los residuos del modelo SLMSTFE en el período considerado. En ella, ahora se observa que los valores del índice de Moran son menores y por tanto, no son significativos comparados con los resultados de la Tabla 1.3 lo que indica que el modelo SLMSTFE controla la dependencia espacial.

Los residuos del modelo SLMSTFE en la Figura 1.6 indican que el modelo SLMSTFE recoge la dependencia temporal ya que los residuos no siguen un patrón de comportamiento.



**Figura 1.6:** Diagrama de cajas de los residuos del modelo SLMSTFE para cada año

## 1.4 Conclusiones

Durante un período de cuatro décadas, se ha abierto una brecha de salud entre los países europeos, en particular entre el este y el oeste (Vågerö 2010). Esta brecha cada vez es mayor (Leon 2011), por lo tanto, es necesario un estudio profundo de las diferencias mencionadas.

Este trabajo cuantifica y compara la mortalidad en Europa utilizando el SMR. Para estudiar la dependencia espacial en los 26 países europeos durante el período 1990-2009 se utilizó el índice de Moran global y para detectar agrupaciones significativas de países con mortalidad similar se utilizó el índice de Moran local. Estas dos últimas medidas se consideran adecuadas para estudiar la dependencia espacial en campos como la epidemiología, la demografía y la econometría. Además, una vez confirmada la dependencia espacial, se implementó un modelo espacial de datos de panel para controlar la dependencia de los países europeos a lo largo del tiempo.

A partir de los resultados relativos a la agrupación de países descritos en la Sección 1.3, las principales conclusiones sobre la cuantificación de la mortalidad y la detección de clusters espaciales entre países europeos son las siguientes.

El SMR sigue siendo superior a 1 a través del tiempo en los países del este de Europa, mientras que en el resto de Europa el SMR es menor que 1. Estos resultados son consistentes con los obtenidos en trabajos como Vaupel, Zhang y van Raalte (2011) y Mackenbach, Karanikolos y McKee (2013), donde los países del este de Europa tienen una esperanza de vida muy baja en comparación con el resto de Europa.

Eslovenia es el único país de Europa del este que tiene una mortalidad observada superior a la esperada como parte de Europa. Estos resultados se confirman en trabajos los trabajos de Trnka y col. (1998) y Zwerling y col. (2011). Estos autores indican que entre 1994-1996 en los países del este de Europa la prevalencia de la tuberculosis era muy alta, por lo que la vacunación primaria se produjo en masa y la revacunación general eran muy comunes. Eslovenia fue el único país de Europa del este, en el que no se aplicó la campaña de revacunación y las pruebas cutáneas tuberculínicas.

Existe una correlación espacial significativa en el SMR de los 26 países europeos, tal y como indica el índice de Moran global.

Además, el índice de Moran local ha detectado dos grandes clusters significativos de países europeos hasta el año 2002. Un cluster de altos niveles de SMR formados por países del este de Europa (Lituania, Letonia, Estonia, Ucrania,

Bielorrusia, Eslovaquia, Hungría y Polonia) y otro cluster de bajos niveles de SMR compuesto por países del oeste de Europa (España, Italia, Francia, Suiza, Alemania, Luxemburgo y Bélgica). Los países con valores no significativos del índice de Moran local no pertenecen a ningún cluster (República Checa, Reino Unido, Dinamarca, Finlandia, Irlanda, Países Bajos, Noruega, Eslovenia, Portugal, Suecia y Austria).

Es importante destacar que el centro del cluster de bajo SMR es Francia. Este centro cluster es único y constante durante el período 1990-2001. Este cluster desaparece a partir del año 2002, lo que indica que la variabilidad de la mortalidad en los países del oeste de Europa ha ido aumentando a partir de 2002. Por el contrario, en el cluster de alto SMR se observan varios centros clusters. Esto es debido a que hay varios clusters de tipo alto SMR los cuales forman un único macrocluster. Estos centros clusters difieren en el mismo período, moviéndose del oeste al este de Europa.

En relación con el trabajo de otros autores, es necesario destacar que, hasta donde sabemos, no se ha llevado a cabo ningún estudio espacio-temporal para detectar clusters de mortalidad similar en Europa, confirmando a su vez que los clusters mencionados son significativos. Existen algunos estudios de mortalidad en Europa, como Meslé y Vallin (2002), Leon (2011) y Bonneux, Huisman y de Beer (2010), pero ninguno de ellos tiene en cuenta las relaciones de vecindad entre países para detectar diferencias en la mortalidad a lo largo del tiempo.

Para modelar la dependencia espacial detectada en los países europeos, se implementó un modelo espacial de datos de panel. En particular, de acuerdo con la tipología de nuestros datos, un modelo de retardo espacial con efecto fijo espacial y temporal (SLMSTFE). La variable dependiente en dicho modelo fue el logaritmo del SMR y las variables independientes fueron: PIB, tasa de actividad y consumo de energía del sector vial. A continuación se detallan las principales conclusiones del modelo implementado. La estimación para el parámetro espacial ( $\lambda$ ) es positiva y altamente significativa. Esto indica que el logaritmo del SMR de un país varía con el logaritmo del SMR de sus vecinos. Específicamente, el valor del logaritmo del SMR de un país aumentará en 34.65 % cuando el logaritmo de los valores SMR correspondientes al entorno también aumenten. Todas las covariables son significativas, lo que significa que variaciones de las tres covariables provocarán variaciones en el logaritmo del SMR de un país.

Los países que forman los diferentes clusters se confirman en las estimaciones de los efectos fijos espaciales del modelo. Las estimaciones de efectos fijos espaciales con un signo negativo pertenecen al grupo de países del oeste de Europa



(bajo SMR), mientras que las estimaciones de efectos fijos espaciales con un signo positivo pertenecen al grupo de países del este de Europa (alto SMR). La mayoría de los países con efectos espaciales no significativos no forman ningún cluster.

En cuanto a los efectos fijos temporales, ninguno de ellos es significativo. Para estudiar si los efectos fijos temporales deben excluirse del modelo se aplicó el test del Multiplicador de Lagrange. La prueba concluyó que ni el efecto espacial ni el temporal pueden ser excluidos del modelo. Además, los efectos temporales se representaron gráficamente y se observó que siguen una tendencia creciente, excepto para el período 1994-1998. Esta evolución desfavorable recoge el colapso del sistema soviético.

Por último, el modelo SLMSTFE es un buen modelo tal y como indican las medidas de bondad de ajuste (el valor de la varianza residual es 0.001 y el valor del coeficiente de determinación es 0.97). El análisis de los residuos del modelo SLMSTFE muestra que el este modelo tiene en cuenta la dependencia espacial y temporal de los datos.

Hay una extensa literatura que muestra que los países del oeste de Europa tienen una mayor esperanza de vida que el resto, como por ejemplo Mackenbach, Karanikolos y McKee (2013), Vågerö (2010) y Meslé (2004). Muchos de estos estudios utilizan la bien conocida esperanza de vida, pero ninguno de ellos tiene en cuenta una metodología espacio-temporal para detectar clusters significativos de países con mortalidad similar, implementando a su vez, un modelo espacial que controle la dependencia espacial de estos países a lo largo del tiempo. Estos modelos, algunos de los todavía se están en desarrollo, se aplican en campos tan variados como la sociología, la epidemiología, la geología, la criminología . . . (Gersmehl 2014), pero hasta ahora, no se han aplicado en el campo actuarial.



# Selección de modelos espaciales de datos de panel en Matlab y R

*El imparable interés en la econometría espacial, las novedosas técnicas estadísticas, la mayor disponibilidad de datos de panel y los avances tecnológicos de los softwares han dado lugar al desarrollo de nuevos paquetes para modelar la dependencia espacial en un panel de datos. El objetivo de este trabajo es seleccionar el mejor modelo espacial de datos de panel utilizando los softwares Matlab y R para su posterior comparación. La metodología estadística empleada tiene en cuenta las relaciones de vecindad entre las unidades espaciales a lo largo del tiempo. Los modelos finalmente seleccionados se validaron mediante dos medidas de bondad de ajuste: el coeficiente de determinación y la varianza residual. Además, sus coeficientes se interpretaron incluyendo los efectos directos e indirectos (spillover espacial). El panel de datos utilizado se corresponde con la mortalidad de 26 países europeos durante el periodo 1990-2009.*

## 2.1 Introducción

Debido a los grandes avances informáticos, cada vez en mayor medida, se generan y almacenan un mayor número de datos, principalmente datos de panel. Un panel de datos está formado por varias unidades geográficas seguidas a lo largo del tiempo. Como ya se mencionó en la Sección 1.1 del capítulo anterior, los datos del panel son más informativos, contienen más variabilidad y, a

menudo, menos colinealidad entre las variables a diferencia de otros datos. Al combinar las dimensiones temporal y espacial, los datos de panel proporcionan más información sobre las variables, disponiendo a su vez, de un mayor número de observaciones. Esto provoca que se incremente el número de grados de libertad produciendo estimaciones eficientes de los parámetros en un modelo de datos de panel (Baltagi 2008; Elhorst 2014).

En consecuencia, el aumento de la disponibilidad de paneles de datos ha estimulado un avance metodológico muy importante en el análisis de paneles espaciales. La econometría espacial, ha considerado modelos con datos de panel donde la variable dependiente o el error están espacialmente autocorrelacionados, incluyendo además, efectos fijos o aleatorios. Estos modelos tienen en cuenta la distancia geográfica de las unidades espaciales, y por tanto, las relaciones de vecindad entre ellas a lo largo del tiempo. Aunque existen paquetes para estimar modelos espaciales transversales en R, Stata y Matlab, son escasos los paquetes que estiman modelos espaciales de datos de panel (Millo y Piras 2012). Hasta ahora, están disponibles el código que complementa a Kapoor, Kelejian y Prucha (2007) en Stata, el código de Elhorst (2011) en MATLAB y por último el paquete `splm` (Millo y Piras 2012) en R.

Como la innovación metodológica está relacionada con el desarrollo de nuevos paquetes, este trabajo presenta la metodología estadística propuesta por Elhorst (2014) para seleccionar el mejor modelo espacial de datos de panel utilizando el software estadístico Matlab. Además, dicha metodología se implementa en R para su posterior comparación.

Una de las conclusiones del Capítulo 1 fue que la brecha de mortalidad entre los países del este y oeste de Europa está aumentando con el tiempo. Así pues, se confirmó que la mortalidad en Europa ha variado en función tanto del tiempo como entre países.

En consecuencia, la base de este trabajo radica en la capacidad de incorporar la dependencia espacial en la mortalidad de países europeos a lo largo del tiempo seleccionando el modelo que mejor represente la distancia geográfica entre los países utilizando los softwares Matlab y R.

El capítulo se ha estructurado de la siguiente manera. La Sección 2.2 empieza detallando los datos que se han utilizado en este estudio. A continuación muestra los diferentes modelos espaciales de datos de panel que más se utilizan en la econometría espacial. La sección finaliza explicando la metodología utilizada para seleccionar el mejor modelo espacial de datos de panel. La Sección 2.3 muestra los resultados de aplicar la metodología espacial definida en la sección

anterior utilizando los softwares Matlab y R. La sección acaba interpretando el mejor modelo espacial que se ha podido conseguir con cada software. Finalmente, la Sección 2.4 presenta las conclusiones más importantes obtenidas en este trabajo.

## 2.2 Materiales y Métodos

### 2.2.1 Datos

En este capítulo se ha empleado el mismo panel de datos que se detalló y utilizó en el capítulo anterior. Estos datos de mortalidad fueron descargados de la Human Mortality Database (2014) para un total de 26 países europeos durante el periodo de tiempo comprendido entre 1990 y 2009.

El estadístico utilizado para cuantificar la mortalidad de los países europeos es el Ratio de Mortalidad Estandarizada (SMR), el cual se describió de forma detallada en la Sección 1.2.2. Recordamos que este ratio se obtiene como el cociente entre el número real de muertes observadas en una población o unidad espacial durante un período de tiempo considerado, y el número de muertes que se esperarían si todas las unidades espaciales tuvieran la misma mortalidad que Europa (Hinde 1998). Su fórmula es la siguiente,

$$SMR_{i,t} = \frac{O_{i,t}}{E_{i,t}} \quad \text{para } i \in \{1, \dots, N\} \quad \text{y } t \in \{1, \dots, T\}$$

donde,

- $i$  son los países europeos con un total de  $N$ ;
- $t$  es el periodo de tiempo en un total de  $T$ , expresado en años;
- $O_{i,t}$  representa el número de muertes observadas para cada país de Europa  $i$  en el año  $t$ ;
- $E_{i,t}$  corresponde a las muertes esperadas para cada país de Europa  $i$  en el año  $t$  bajo la hipótesis de que cada país tiene la misma mortalidad que el conjunto de países de Europa.

El logaritmo del SMR será la variable dependiente en el modelo espacial, puesto que el SMR tiene una fuerte asimetría positiva. Las variables independientes en

el modelo espacial se obtuvieron de la web The World Bank Database (2015) con información relativa a los 26 países europeos durante el periodo 1990-2009. Estas variables fueron: producto interior bruto (PIB), crecimiento de la población, tasa de actividad y consumo de energía del sector vial y tasa de natalidad, las cuales se detallaron en la Sección 1.2.1. Recordar que el estudio de multicolinealidad en la Sección 1.2.1 indicó que la variable crecimiento de la población producía multicolinealidad en el panel de datos, por lo que se desestimó de los análisis.

Los análisis estadísticos se realizaron utilizando dos softwares: Matlab (MathWorks 2015) y R project (R Core Team 2015). Las rutinas de Matlab para estimar los modelos espaciales, se descargaron el 06/05/2015 en la siguiente web <http://www.regroningen.nl/>. Éstas fueron escritas por Elhorst (2011). Los paquetes utilizados en R para obtener los modelos espaciales fueron: `splm` (Millo y Piras 2012), `plm` (Croissant y Millo 2008) y `spdep` (Bivand 2012; Charpentier 2014).

### 2.2.2 Modelos espaciales de datos de panel

Un modelo de datos de panel es un modelo de regresión que utiliza la dimensión temporal y espacial de los datos para la estimación de los parámetros de interés. Estos modelos, permiten modelar la heterogeneidad no observada producida tanto por las unidades espaciales estudiadas como por el tiempo. La heterogeneidad no observada la producen las variables de las cuales no tenemos información pero afectan a la variable de interés. Es importante controlar esa heterogeneidad no observable para poder reducir problemas de multicolinealidad entre las variables y así estimar de forma eficiente los parámetros en un modelo de datos de panel (Kennedy 2003).

Como ya se detalló en la Sección 1.2.3, la regresión por mínimos cuadrados ordinarios (OLS) omite la dimensión espacial y temporal en un panel de datos y supone que la constante del modelo es la misma para todas las unidades espaciales. Para superar esta debilidad, nacieron dos modelos: el modelo de efectos fijos y el modelo de efectos aleatorios. El primero considera que el efecto tiene un valor fijo para cada unidad transversal y/o temporal, mientras que el segundo tienen en cuenta que el efecto es una variable aleatoria con una media y una varianza no nula.

A continuación, se van a detallar los modelos espaciales de los modelos que, finalmente, se estimarán de acuerdo con las rutinas de Elhorst (2014):

- *Modelo de retardo espacial con efecto fijo espacial y temporal (SLMSTFE)*. Sus siglas provienen del ingles “Spatial Lag Model with Spatial and Time Fixed Effects”.
- *Modelo de error espacial con efecto fijo espacial y temporal (SEMSTFE)*. Sus siglas provienen del ingles “Spatial Error Model with Spatial and Time Fixed Effects”.

Cabe destacar que en estos dos modelos se puede considerar sólo el efecto fijo espacial o temporal (no ambos). En este capítulo se detalla el modelo con ambos efectos (“two ways”), puesto que es el modelo general, ya que a partir de éste se obtiene el modelo de retardo espacial con efecto fijo espacial y el modelo de retardo espacial con efecto fijo temporal.

- *Modelo de retardo espacial con efecto aleatorio (SLMSTRE)*. Sus siglas provienen del ingles “Spatial Lag Model with Random Effects”. En este modelo, el efecto aleatorio es el efecto espacial, el temporal se considera fijo.
- *Modelo de error espacial con efecto aleatorio (SEMRE)*. Sus siglas provienen del ingles “Spatial Error Model with Random Effects”.
- *Modelo Durbin espacial (SDM)*. Sus siglas provienen del ingles “Spatial Durbin Model”. Este modelo incluye la correlación espacial en las covariables en los modelos SLMSTFE y SLMSTRE.
- *Modelo de error espacial Durbin (SDEM)*. Sus siglas provienen del ingles “Spatial Durbin Error Model”. Este modelo incluye la correlación espacial en las covariables en los modelos SEMSTFE y SEMRE.

A continuación se proporcionan las ecuaciones matemáticas de los modelos que, finalmente, se implementarán.

- SLMSTFE

$$y_{it} = \alpha + \lambda \sum_{j=1}^N W_{ij} y_{jt} + \beta + \mu_i x_{it} + \nu_t + \epsilon_{it} \quad (2.1)$$

- SLMSTRE

$$y_{it} = \alpha + \lambda \sum_{j=1}^N W_{ij} y_{jt} + \beta x_{it} + \phi + \nu_t + \epsilon_{it}$$

- SDM

Incluyendo efectos fijos:

$$y_{it} = \alpha + \lambda \sum_{j=1}^N W_{ij} y_{jt} + \beta x_{it} + \mu_i + \nu_t + \delta \sum_{j=1}^N W_{ij} x_{jt} + \epsilon_{it} \quad (2.2)$$

Incluyendo efectos aleatorios

$$y_{it} = \alpha + \lambda \sum_{j=1}^N W_{ij} y_{jt} + \beta x_{it} + \phi + \nu_t + \delta \sum_{j=1}^N W_{ij} x_{jt} + \epsilon_{it}$$

donde:

- $i$  representa los países;
- $t$  representa los años;
- $y_{it}$  representa un vector de dimensión  $NT \times 1$  correspondiente a las observaciones de la variable dependiente para cada país  $i$  y año  $t$ ;
- $x_{it}$  es una matriz de dimensión  $NT \times k$  de observaciones de las variables explicativas, donde  $k$  el número de variables exógenas;
- $\beta$  es un vector de parámetros desconocidos asociados a las variables independientes de dimensión  $k \times 1$  (no espacial);
- $W_{ij}$  es la matriz de pesos espaciales o de contigüidad de dimensión  $N \times N$ , donde  $i$  y  $j$  representan dos países cualquiera de los  $N$  países totales. Igual que en capítulo anterior, hemos considerado que un país es vecino de otro cuando ambos comparten frontera y vértices comunes (criterio reina) donde la estructura espacial es de primer orden (Sección 1.2.2).

El resto son los parámetros que, dependiendo del modelo seleccionado, se estimarán. Su interpretación es la siguiente:



- $\lambda$  y  $\delta$  son los parámetros espaciales. En concreto,  $\lambda$  es el parámetro autorregresivo espacial asociado a la variable dependiente y  $\delta$  es un vector de dimensión  $k \times 1$  de parámetros espaciales asociados a las variables independientes;
- $\alpha$  es el intercepto del modelo;  
Representa el valor medio de la variable dependiente cuando todas las variables independientes son cero. Este modelo considera una variable dummy para cada unidad espacial  $\mu_i$  y una variable dummy para cada unidad temporal  $\nu_t$  (Elhorst 2003). Estos interceptos ( $\alpha + \mu_i + \nu_t$ ) se estimarán bajo la restricción  $\sum_{i=1}^N \mu_i = 0$  y  $\sum_{t=1}^T \nu_t = 0$  (Baltagi 2008; Hsiao 2014). De esta forma el efecto espacial representa la desviación de la unidad espacial  $i$  respecto del promedio  $\alpha$  y el efecto temporal representa la desviación de la unidad temporal  $t$  respecto del promedio  $\alpha$ . Por ello,  $\alpha$  es el efecto que recoge en términos medios la heterogeneidad no observable producida por variables que permanecen constantes entre países y con el tiempo.
- $\mu_i$  es el efecto espacial fijo que recoge la heterogeneidad no observable producida por variables que cambian a través de los países, pero permanecen constantes en el tiempo. Es un vector dimensión  $N \times 1$ ;
- $\nu_t$  es el efecto fijo temporal que captura la heterogeneidad no observable producida por variables que cambian con el tiempo, pero permanecen constantes entre los países. Es un vector dimensión  $T \times 1$ ;
- $\phi$  es el efecto espacial independiente e idénticamente distribuido con media 0 y varianza  $\sigma^2 \neq 0$ ;
- $\epsilon_{it}$  es un vector de términos del error independiente e idénticamente distribuido de dimensión  $NT \times 1$ , el cual recoge la heterogeneidad no observable producida por variables que cambian tanto a través de los países como a través del tiempo. Este vector no está espacialmente autocorrelacionado a diferencia de los modelos SEMSTFE, SEMRE y SDEM.

A menudo, en muchas aplicaciones empíricas, los coeficientes asociados a las covariables en los modelos espaciales se interpretan incorrectamente, como si fueran simples derivadas parciales. Esta interpretación, no es válida para mo-

delos con dependencia espacial en la variable dependiente o en las variables explicativas (Elhorst 2014; Golgher y Voss 2016) debido a que estos modelos pueden generar un proceso llamado spillover total o global. Este efecto spillover total indica que los cambios de una variable independiente en una determinada unidad espacial, afectarán directamente a la variable dependiente en esa unidad espacial, pero también afectará indirectamente a los vecinos de sus vecinos desencadenando un efecto feedback que finalmente consigue el equilibrio final afectando a la unidad espacial original (Ward y Gleditsch 2008). Así pues, el efecto spillover total se representa como la suma del efecto directo e indirecto. A continuación, la Tabla 2.1 muestra los efectos directos e indirectos correspondientes a los diferentes modelos espaciales econométricos (Vega y Elhorst 2012).

**Tabla 2.1** Efectos directos e indirectos para los diferentes modelos espaciales econométricos

Modelo	Efecto Directo	Efecto Indirecto
OLS y SEM	$\beta$	0
SLM	Elementos diagonal $(I_{it} - \lambda W_{ij})^{-1} \beta$	Elementos fuera diagonal $(I_{it} - \lambda W_{ij})^{-1} \beta$
SDEM	$\beta$	$\delta$
SDM	Elementos diagonal $(I_{it} - \lambda W_{ij})^{-1} (\beta + W_{ij} \delta)$	Elementos fuera diagonal $(I_{it} - \lambda W_{ij})^{-1} (\beta + W_{ij} \delta)$

Nota:

OLS.- Regresión por mínimos cuadrados ordinarios

SEM.- Modelo de error espacial. Sus siglas provienen del inglés "Spatial Error Model"

SLM.- Modelo de retardo espacial. Sus siglas provienen del inglés "Spatial Lag Model"

SDEM.- Modelo de error espacial Durbin. Sus siglas provienen del inglés "Spatial Durbin Error Model"

SDM.- Modelo Durbin espacial. Sus siglas provienen del inglés "Spatial Durbin Model"

Para todos los modelos espaciales de la Tabla 2.1, la matriz de contigüidad o de pesos espaciales se descompone de la siguiente forma:

$$(I_{it} - \lambda W_{ij})^{-1} = I_{it} + \lambda W_{ij} + \lambda^2 W_{ij}^2 + \lambda^3 W_{ij}^3 \dots \quad (2.3)$$

donde:

- $I_{it}$  la matriz identidad de dimensión  $N \times T$ .
- $W_{ij}$  es la matriz de contigüidad o de pesos espaciales. Cuando  $W_{ij}$  se eleva a la potencia de 1 representa los vecinos de primer orden. La matriz  $W_{ij}^2$  refleja los vecinos de segundo orden, aquellos que son vecinos de los vecinos de primer orden. La matriz  $W_{ij}^3$  representa los vecinos de tercer orden y así sucesivamente (LeSage y Pace 2009). De esta forma, la ecuación (2.3) refleja el efecto de feedback, es decir, los efectos que pasan a través de unidades vecinas vuelven a la unidad espacial original. En LeSage y Pace (2009) se puede ver un ejemplo.

A continuación, vamos a mostrar la inclusión de los efectos directos e indirectos únicamente en los dos modelos finales que se obtendrán en la Sección 2.3.

La expresión alternativa al modelo SLMSTFE (ecuación (2.1)) tendría la siguiente forma según LeSage y Pace (2009):

$$y_{it} = (I_{it} - \lambda W_{ij})^{-1}(\alpha v_{it} + \beta x_{it} + \epsilon_{it}) \quad (2.4)$$

donde,

- $y_{it}$  representa un vector de dimensión  $NT \times 1$  correspondiente a las observaciones de la variable dependiente para cada país  $i$  y año  $t$ ;
- $I_{it}$  es la matriz unitaria de dimensión  $NT \times 1$ ;
- $\lambda$  es el parámetro espacial asociado a la variable dependiente;
- $x_{it}$  es una matriz de dimensión  $NT \times k$  de observaciones de las variables explicativas; donde  $k$  el número de variables exógenas;

- $\beta$  es un vector de parámetros desconocidos asociados a las variables independientes de dimensión  $k \times 1$  (no espacial);
- $\alpha$  es el intercepto del modelo;
- $\iota_{it}$  es un vector unitario de dimensión  $NT \times 1$ ;
- $W_{ij}$  es la matriz de pesos espaciales;
- $\epsilon_{it}$  es el vector de términos del error de dimensión  $NT \times 1$ .

Para el modelo SDM, la inclusión de los efectos directos e indirectos en la ecuación (2.2), quedaría de la siguiente manera según LeSage y Pace (2009):

$$y_{it} = (I_{it} - \lambda W_{ij})^{-1} (\alpha \iota_{it} + \beta x_{it} + \delta \sum_{j=1}^N W_{ij} x_{jt} + \epsilon_{it}) \quad (2.5)$$

donde  $\delta$  es el parámetro espacial asociado a las  $k$  variables independientes.

La diferencia entre el modelo SLMSTFE y el modelo SDM es que este último incorpora la correlación espacial en las variables independientes. Ahora sí, la ecuaciones (2.4) y (2.5) recogen el proceso de spillover total.

De acuerdo con la ecuación (2.4) y la Tabla 2.1, el tamaño de los efectos directos e indirectos en el modelo SLMSTFE depende de la matriz de pesos espaciales  $W_{ij}$ , el parámetro espacial  $\lambda$  y del vector de parámetros asociados a las variables independientes  $\beta$ , mientras que en el modelo SDM, además de los parámetros anteriores, también depende del parámetro espacial asociado a las variables independientes  $\delta$  según la ecuación (2.5) y la Tabla 2.1.

### 2.2.3 Metodología estadística para comparar y seleccionar modelos espaciales de datos de panel

A continuación, se van a definir los tests estadísticos y las medidas de bondad de ajuste que sugiere Elhorst (2014) para comparar y seleccionar modelos espaciales de datos de panel:

- La prueba clásica del Multiplicador de Lagrange (LM).- Sus singlas provienen del inglés “Lagrange Multiplier” test, el cual permite conocer si es significativo considerar en el modelo de datos de panel el retardo (dependencia) espacial en la variable dependiente o en el error. Para ello, estudia la interacción de los efectos espaciales en los datos de corte transversal. Esta prueba se basa en los valores de la función log-verosimilitud de diferentes modelos. La hipótesis nula es que la variable dependiente o el error no está espacialmente autocorrelacionado, y si se rechaza con un nivel de significación del 5 % o 1 % implica la inclusión en el modelo del retardo (dependencia) espacial en la variable dependiente o en el error. Este test fue propuesto por Burridge (1980) y Anselin (1988).
- El cociente de verosimilitud (LR).- Sus singlas provienen del inglés “Likelihood-ratio” test, el cual contrasta la hipótesis de si el efecto fijo espacial o temporal son significativos, y por tanto, se deben de considerar en el modelo. Esta prueba, igual que la anterior, se basa en los valores de la función log-verosimilitud de diferentes modelos. La hipótesis nula expresa que el efecto fijo espacial o temporal no es significativo, es decir, no es significativo añadir el efecto considerado al modelo. Shiba y Tsurumi (1988) proporcionaron este test para contrastar la hipótesis nula.
- Test de Wald. Esta prueba ayudará a confirmar si el Modelo Durbin es apropiado para el análisis. Las hipótesis nula establece si el SDM o SDEM puede ser simplificado a un modelo con retardo o error espacial. Si dicha hipótesis se rechaza, entonces el SDM o SDEM es el que mejor describe los datos (Elhorst 2014).
- Test de Hausman comprueba si el efecto del modelo ha de tratarse como fijo o aleatorio. Si la hipótesis nula no puede rechazarse, indica que se debe de utilizar el modelo de efectos aleatorios frente al modelo de efectos fijos (Baltagi, Bresson y Pirotte 2003).
- Coeficiente de determinación  $R^2$  y la varianza residual  $\sigma^2$  son las dos medidas de bondad de ajuste de los modelos. Cuanto mas próximo está el  $R^2$  a 1 y menor es la  $\sigma^2$ , mejor será el modelo.

## 2.3 Resultados

### 2.3.1 Selección del mejor modelo espacial de datos de panel en Matlab y R.

Como ya mencionamos al final de la Sección 2.2.1, para seleccionar e implementar el mejor modelo espacial a los datos de mortalidad europea, hemos adaptado las rutinas que sugiere Elhorst (2011) en Matlab y, a su vez, hemos implementado un código similar en R. El código en Matlab se adjunta en el Anexo B y el código de R en el Anexo A. A continuación se irán detallando los pasos a seguir así como los resultados obtenidos utilizando ambos softwares para su comparación.

*En primer lugar, se debe estudiar la elección de un modelo de datos de panel (no espacial), frente a una simple regresión por mínimos cuadrados ordinarios. Después, se analizará si el modelo de datos de panel seleccionado se puede convertir en un modelo espacial. Para ello, es necesario estimar los siguientes modelos con datos de panel no espaciales:*

- Regresión por Mínimos Cuadrados Ordinarios (OLS).- Esta regresión no considera la dimensión temporal ni espacial de los datos.
- Modelo de datos en panel con Efecto Fijo Espacial (MSFE).- Su nombre proviene de las siglas en inglés “Model with Spatial Fixed Effect”. Es un modelo de datos de panel con efecto fijo espacial. Este efecto controla la heterogeneidad no observable producida por variables de las cuales no tenemos información pero que afectan a la variable de interés. Estas variables varían con el país pero permanecen constantes a lo largo del tiempo.
- Modelo de datos en panel con Efecto Fijo Temporal (MTFE).- Su nombre proviene de las siglas en inglés “Model with Time Fixed Effects”. Este efecto controla la heterogeneidad no observable producida por variables de las cuales no tenemos información pero que afectan a la variable de interés. Estas variables varían con el tiempo pero permanecen constantes entre los países.
- Modelo de datos en panel con Efecto Fijo Espacial y Temporal (MSTFE).- Su siglas en inglés provienen de “Model with Spatial and Time Fixed Effects”. Es un modelo de datos de panel con el efecto fijo tanto espacial como el temporal. Este modelo es también conocido como “two ways”, ya que, incluye ambos efectos fijos.

Cabe destacar que, a diferencia del modelo SLMSTFE, el modelo MSTFE no considera la dependencia o retardo espacial en la variable dependiente. En los modelos MSFE y MTFE sólo se considera un efecto, y no ambos, donde tampoco tienen en cuenta la dependencia espacial en la variable dependiente.

A continuación, se calcula la prueba clásica LM en cada uno de los 4 modelos con el objetivo de analizar si el modelo seleccionado puede convertirse en un modelo espacial. Para su obtención, se ha utilizado el fichero denominado *demoLMsarsem\_panel* en Matlab y en R la función `plm` del paquete `plm` (Croissant y Millo 2008) para los modelos y la función `slmtest` del paquete `splm` (Millo y Piras 2012) para la prueba clásica LM. Los resultados de estimar los 4 modelos definidos junto con la prueba clásica LM utilizando el software Matlab y R se encuentran en la Tabla 2.2. Las principales conclusiones que se pueden extraer de la Tabla 2.2 son las siguientes:

- Los valores obtenidos en las estimaciones de los parámetros de los modelos, la varianza residual  $\sigma^2$ , el coeficiente de determinación  $R^2$  sin la contribución de los efectos fijos y los resultados del test LM son los mismos utilizando ambos softwares.
- La salida de los modelos en R no muestra directamente el valor del  $\sigma^2$ .
- En cuanto al  $R^2$ , el software MATLAB, a diferencia de R, proporciona su valor incluyendo los efectos junto con el valor de la función Log-likelihood. El software R muestra la suma de cuadrados total, la suma de cuadrados residual y el valor del estadístico F y Matlab no.
- Se observa que el modelo de datos de panel que incluye el efecto fijo espacial y temporal es el que obtiene mayor  $R^2$  con la contribución de los efectos fijos y menor  $\sigma^2$ . Esto indica, a priori, que ambos efectos son conjuntamente significativos y es importante incluirlos en el modelo. Así pues, se puede confirmar que se debe de desestimar una regresión OLS y por contra considerar un modelo con datos de panel MSTFE. Cabe destacar el bajo  $R^2$  que proporciona el modelo MTFE (0.3160), el cual aumenta a 0.9710 considerando el efecto espacial. Los malos resultados de este modelo se confirman en el ejemplo que proporciona Elhorst (2014) para estimar la demanda de cigarrillos en 46 estados de USA mediante un modelo de datos de panel.
- La significatividad y, en algún caso, el signo de variables como tasa bruta de natalidad, tasa de actividad y PIB difieren entre los modelos OLS y MSTFE. Esto es debido a que el modelo OLS no considera la dimensión espacial y temporal de los datos, a diferencia del MSTFE que si las consi-



dera. Analizando el modelo MSTFE seleccionado por conseguir el mayor  $R^2$ , todas las variables tienen el signo esperado excepto la variable PIB. Este resultado es acorde con el trabajo de EUROSTAT (2013). En él se muestra que, aunque las condiciones de salud están relacionadas con el PIB, éstas no dependen totalmente de la producción de riqueza en una economía determinada. Las diferencias entre los países también pueden atribuirse a otros factores, por ejemplo si los proveedores son organizaciones privadas o públicas, la calidad de los servicios de salud, los factores ambientales y las opciones culturales también afectan los resultados de la salud. Así pues, el signo asociado al coeficiente de la variable PIB puede ser positivo. La única variable que no es significativa en el modelo es la tasa bruta de natalidad, por lo que se decide excluirla en los posteriores análisis. Destacar, que los coeficientes de todas las covariables son cercanos a cero. Esto se debe a que la variable dependiente se expresa en logaritmos y toma valores muy pequeños.

- La prueba clásica LM indica que considerar el retardo espacial de la variable dependiente en el modelo MSTFE es significativo, convirtiéndolo así en un modelo espacial SLMSTFE. Considerar la correlación espacial del error en el modelo MSTFE es menos significativo, por lo que se selecciona el modelo SLMSTFE el cual incluye el efecto fijo espacial y temporal.
- La conclusión de este primer paso es que se debe de seleccionar un modelo espacial de datos en panel, en concreto, SLMSTFE con efecto fijo espacial y temporal frente a un modelo no espacial.

Tabla 2.2 Estimación de modelos no espaciales de datos de panel en Matlab y R.

Parámetros	OLS	MSFE	MTFE	MSTFE
$\alpha$ (Matlab)	0.7095 *	0.4512 *	0.7360 *	0.4256 *
$\beta_{tasa\ natalidad}$	-0.0291 *	0.0016	-0.0332 *	0.0010
$\beta_{tasa\ actividad}$	-0.0018	-0.0066 *	-0.0016	-0.0058 *
$\beta_{consumo\ energia\ vial}$	-0.0146 *	-0.0020 *	-0.0148 *	-0.0033 *
$\beta_{PIB}$	0.0037	0.0027 *	0.0078 *	0.0046 *
$\sigma^2$	0.0402	0.0018	0.0392	0.0017
$R^2$ sin la contribución de los efectos fijos	0.2998	0.2101	0.3158	0.2575
Test clásico LM retardo espacial	301.4027 *	42.6894 *	290.4052 *	40.1192 *
Test clásico LM error espacial	197.2800 *	37.6552 *	177.1406 *	26.9007 *
Función Log-likelihood (Matlab)	100.1503	909.5316	106.2504	928.1107
$R^2$ con la contribución de los efectos fijos (Matlab)	0.2998	0.9689	0.3160	0.9710
Suma de cuadrados total (R)	29.5820	1.1661	29.5710	1.1549
Suma de cuadrados residual (R)	20.7130	0.9210	20.2330	0.8575
F-estadístico (R)	55.1298 *	32.5896 *	57.2315 *	40.8401 *

\*p-valores &lt;0.05 son significativos

Al ser una tabla comparativa de todos los parámetros comunes a los distintos modelos, no mostramos la estimación de los efectos fijos de cada modelo.

La estimación de  $\alpha$  en los modelos de datos de panel se obtiene utilizando Matlab. El paquete **plm** en R no lo tiene implementado. Por contra el paquete **splm**, para modelos espaciales, si que lo permite.

**Tabla 2.3:** Resultado de la prueba LR en Matlab

<b>Efecto</b>	<b>Test LR</b>	<b>Grados de libertad</b>	<b>p-valor</b>
Espacial	1672.5700	26	0.0000 *
Temporal	37.7142	20	0.0096 *

\*p-valores  $<0.05$  son significativos

El segundo paso es investigar si los efectos espaciales o temporales fijos se deben de incluir en el modelo. Para ello, se utilizó la prueba de Razón de Verosimilitud (LR) en Matlab utilizando la función `LMSarsem_panel` del fichero denominado `demoLMSarsem_panel`. Dicha prueba compara el modelo MSTFE versus MSFE y MTFE cuya hipótesis nula es que el efecto fijo espacial o temporal no es significativo y por tanto, no se debe de incluir en el modelo. La Tabla 2.3 muestra los resultados del test LR en Matlab, la cual justifica el MSTFE obtenido en el paso anterior dado que los p-valores de ambos efectos son significativos.

La prueba LR no está implementada en los paquetes `plm` y `splm` de R. En su lugar, se utilizó la función `plmtest` del paquete `plm` (Croissant y Millo 2008) en R. Dicha función obtiene el resultado de la prueba LM por Breusch y Pagan (1980). El objetivo de esta prueba es contrastar la incorporación de efecto espacial o efecto temporal o efectos espaciales y temporales en el modelo. Para ello, compara el modelo OLS versus MSFE, MTFE y MSTFE. Si el p-valor es menor que 0.05 la hipótesis nula será rechazada y por tanto será necesario incluir los efectos fijos considerados en el modelo. En dicha función, se debe de especificar el modelo de referencia (OLS), el efecto que se desea añadir al modelo y el tipo del test, en nuestro caso el de Breush-Pagan. Los resultados de la prueba LM se muestran en la Tabla 2.4, la cual incluye el valor del estadístico utilizado en el contraste, los grados de libertad y el p-valor asociado a cada una de las pruebas. La prueba LM concluye que el efecto espacial y temporal deben de considerarse en el modelo, ya que el p-valor obtenido es el más significativo. Por lo tanto, se confirma el modelo MSTFE obtenido en el paso anterior.

A partir de los resultados de los dos pasos anteriores se confirma que hemos de considerar un SLMSTFE con efecto fijo espacial y temporal.

Si el modelo OLS se ha rechazado en favor de un modelo espacial en base a la prueba clásica LM, hay que estudiar con detenimiento el modelo espacial seleccionado (Elhorst 2014). Por este motivo, LeSage y Pace (2009) recomiendan

**Tabla 2.4:** Resultado de la prueba LM para el efecto espacial, temporal y ambos en R

Prueba LM	$\chi^2$	Grados de libertad	p-valor
Espacial	4168.5	1	0.0000 *
Temporal	2.3718	1	0.1235
Espacial y Temporal	4170.9	2	0.0000 *

\*p-valores <0.05 son significativos

considerar también el Modelo Durbin. En nuestro caso, vamos a considerar un Modelo Durbin espacial (SDM) con efecto fijo espacial y temporal y no un Modelo de error espacial Durbin (SDEM). Como ya se detalló en la Sección 2.2.2 el SDM incluye la correlación espacial en las covariables de los modelos SLMSTFE y SLMSTRE. Así pues, *el tercer paso es estimar el modelo espacial SDM.*

Para obtener el SDM en Matlab se ha utilizando la función `sar_panel_FE` del fichero `demopanelcompare`.

Por contra, hasta la actualidad, el SDM no se puede calcular con el paquete `splm` de Millo y Piras (2012). Por tanto, el mejor modelo espacial de datos en panel que se ha podido obtener con R ha sido el modelo SLMSTFE mientras que en Matlab fue un SDM. Destacar que la función `lagsarlm` del paquete `spdep` de Bivand (2012) ajusta un SDM en R pero con datos de corte transversal, por lo que no podemos utilizar dicha función.

*El cuarto paso es estudiar si los efectos que se deben de incluir en el modelo han de considerarse fijos o aleatorios.* Para ello se calculado el test de Hausman. Recordar que la hipótesis nula de esta prueba, indica que se ha de adoptar un modelo de efectos aleatorios. La Tabla 2.5 muestra los resultados de aplicar dicho test a los modelos SDM y SLMSTFE. Para el modelo SDM se ha utilizando la función `hausman` del fichero `demopanelcompare` en Matlab. Para el modelo SLMSTFE se ha utilizado la función `sphtest` del paquete `splm` donde es necesario especificar los dos modelos: el modelo SLMSTFE y el modelo SLMSTRE. Los resultados en Matlab, indican que se ha de adoptar el SMD con efectos fijos mientras que en R se observa que se ha de adoptar el modelo de efectos fijos SLMSTFE, rechazando en ambos casos el modelo de efectos aleatorios.

Por todos los análisis anteriores, podemos concluir que finalmente el modelo seleccionado en Matlab es un modelo Durbin espacial SDM. Mientras que el modelo seleccionado en R es un modelo con retardo espacial en la variable dependiente y efecto fijo espacial y temporal SLMSTFE.

**Tabla 2.5:** Resultado del test de Hausman en Matlab y R

Software	$\chi^2$	Grados de libertad	p-valor
Matlab	490.4511	7	0.0000 *
R	23.3310	3	0.0000 *

\*p-valores  $<0.05$  son significativos

### 2.3.2 Estimación modelos finales: SDM en Matlab y SLMSTFE en R.

Una vez seleccionados los modelos finales en ambos softwares, el siguiente paso es la estimación e interpretación de cada uno de ellos.

#### *Modelo SDM obtenido en Matlab*

La Tabla 2.6 muestra la estimación de parámetros del modelo SDM, dos medidas de bondad de ajuste ( $R^2$  y  $\sigma^2$ ) y el test de Wald en Matlab. En ella, se observa que el parámetro espacial  $\lambda$  es positivo (0.3522) y estadísticamente significativo (p-valor  $<0.05$ ). Este parámetro indica que, además de las contribuciones que las covariables realizan al logaritmo del SMR de un país, su valor aumenta en 35.22% cuando en promedio el logaritmo de los valores del SMR correspondientes al entorno también aumentan. Las medidas de bondad de ajuste del modelo indican que es un buen modelo, ya que, el coeficiente de determinación es elevado (0.9763) y la varianza residual tiene un valor pequeño (0.0015) comparado con la varianza de la variable dependiente. El test de Wald confirma que hemos de considerar el SDM ya que es el que mejor describe a los datos (se rechaza el modelo SLMSTFE en favor del SDM).

Los resultados de la estimación de los efectos fijos espaciales  $\mu_i$  del modelo SDM se muestran en la Tabla 2.7, la cual incluye el valor estimado de éstos, el valor del estadístico t y los p-valores asociados a cada uno de los parámetros. El valor de  $\mu_i$  representa la desviación del país  $i$  respecto al intercepto  $\alpha$ . En general, las estimaciones de los efectos espaciales con un signo negativo corresponden a los países del oeste de Europa los cuales tienen un bajo SMR. Esto significa que las variables omitidas constantes en el tiempo afectan disminuyendo el logaritmo del SMR, en comparación con el promedio  $\alpha$ . Por contra, las estimaciones de los efectos espaciales con un signo positivo pertenecen a los países del este de Europa los cuales tienen un alto SMR. Esto significa que las variables omitidas constantes en el tiempo afectan aumentando el logaritmo del SMR, en comparación con el promedio  $\alpha$ .

**Tabla 2.6:** Estimación del modelo SDM con efecto fijo espacial y temporal en Matlab.

Parámetros	Estimación	p-valor
$\alpha$	0.5275	0.0000 *
$\lambda$	0.3522	0.0000 *
$\beta_{tasa\ actividad}$	-0.0007	0.5424
$\beta_{consumo\ energia\ vial}$	-0.0048	0.0000 *
$\beta_{PIB}$	0.0042	0.0000 *
$\delta_{tasa\ actividad}$	0.0071	0.0000 *
$\delta_{consumo\ energia\ vial}$	0.0026	0.0624
$\delta_{PIB}$	-0.0028	0.0107 *
Test de Wald retardo espacial	27.4798	0.0000 *
$\sigma^2$	0.0015	
$R^2$ con la contribución de los efectos fijos	0.9763	
$R^2$ sin la contribución de los efectos fijos	0.3180	
LogL	968.4017	

\*p-valores <0.05 son significativos

Los resultados de la estimación de los efectos fijos temporales  $\nu_t$  del modelo SDM se muestran en la Tabla 2.8, la cual incluye el valor estimado de éstos, el valor del estadístico t y los p-valores asociados a cada uno de los parámetros. El valor de  $\nu_t$  representa la desviación del año  $t$  respecto al intercepto  $\alpha$ . En general, las estimaciones de los efectos temporales con un signo negativo significa que las variables omitidas constantes entre países afectan disminuyendo el logaritmo del SMR, en comparación con el promedio  $\alpha$ . Por contra, las estimaciones de los efectos temporales con un signo positivo significa que las variables omitidas constantes entre países afectan aumentando el logaritmo del SMR, en comparación con el promedio  $\alpha$ . Destacar que aunque ningún  $\nu_t$  es significativo, no podemos excluirlos del modelo tal y como indicó la prueba LR en la Tabla 2.3.

Adicionalmente, estos  $\nu_t$  se representaron gráficamente en la Figura 2.1. En ella, se puede observar que los efectos temporales siguen una tendencia creciente excepto para el período 1994-1997. Esta evolución desfavorable recoge el colapso del sistema soviético. En el año 1994, Rusia tuvo la peor esperanza de vida, así como Estonia, Letonia y Lituania. Desde 1994 hasta 1998, la esperanza de vida en las Repúblicas Bálticas y Rusia creció. Este fue un signo de ajuste a las nuevas circunstancias (Vågerö 2010).

**Tabla 2.7:** Estimación de los efectos espaciales del SDM en Matlab

<b>País</b>	<b>Estimación</b>	<b>t-valor</b>	<b>p-valor</b>
Austria	-0.1365	-1.5691	0.1166
Bélgica	-0.1241	-1.4490	0.1473
Bielorrusia	0.2796	3.2946	0.0009 *
Suiza	-0.2331	-2.5504	0.0107 *
República Checa	0.1161	1.3494	0.1772
Alemania	-0.1033	-1.1664	0.2434
Dinamarca	0.0167	0.1840	0.8539
Estonia	0.1362	1.5134	0.1301
España	-0.1909	-2.1856	0.0288 *
Finlandia	-0.0289	-0.3184	0.7501
Francia	-0.2549	-2.9378	0.0033 *
Hungría	0.2314	2.8166	0.0048 *
Irlanda	0.0211	0.2291	0.8187
Italia	-0.1786	-2.0496	0.0403 *
Lituania	0.1255	1.4489	0.1473
Luxemburgo	0.0355	0.3969	0.6914
Letonia	0.2821	3.1939	0.0014 *
Países Bajos	0.1543	-1.8230	0.0682
Noruega	-0.1039	-1.1421	0.2534
Polonia	0.0753	0.8952	0.3706
Portugal	-0.0095	-0.1073	0.9145
Suecia	-0.1421	-1.5628	0.1180
Eslovenia	-0.0227	-0.2711	0.7862
Eslovaquia	0.1141	1.3658	0.1719
Ucrania	0.3586	4.3979	0.0000 *
Reino Unido	-0.109183	-1.1638	0.2444


\*p-valores <0.05 son significativos

**Tabla 2.8:** Estimación de los efectos temporales del SDM en Matlab

Año	Estimación	t-valor	p-valor
1990	-0.0010	-0.0124	0.9901
1991	-0.0008	-0.0100	0.9919
1992	0.0025	0.0304	0.9757
1993	0.0037	0.0448	0.9642
1994	-0.0013	-0.0160	0.9872
1995	-0.0071	-0.0836	0.9333
1996	-0.0126	-0.1477	0.8825
1997	-0.0103	-0.1190	0.9052
1998	-0.0030	-0.0355	0.9716
1999	-0.0036	-0.0423	0.9662
2000	-0.0060	-0.0686	0.9452
2001	-0.0011	-0.0130	0.9895
2002	0.0007	0.0087	0.9930
2003	-0.0040	-0.0462	0.9630
2004	-0.0011	-0.0132	0.9894
2005	-0.0020	-0.0232	0.9814
2006	0.0064	0.0715	0.9429
2007	0.0097	0.1070	0.9147
2008	0.0093	0.1057	0.9157
2009	0.0220	0.2598	0.7950

\*p-valores  $<0.05$  son significativos





**Figura 2.1:** Representación gráfica de los efectos temporales del SDM.

Los resultados recogidos de la Tabla 2.9 muestran las estimaciones junto con el valor del estadístico  $t$  de los efectos directos, indirectos y totales basados en los parámetros estimados del modelo SDM para las covariables. Destacar que estos coeficientes son cercanos a cero debido a que la variable dependiente se expresa en logaritmos, y por tanto, toma valores muy pequeños.

Las estimaciones de los efectos directos asociados a las tres variables explicativas tienen los signos esperados. La tasa de actividad toma el valor de  $-0.0017$ , consumo de energía vial  $-0.0047$  y el PIB  $0.0040$ . Cabe mencionar que estas estimaciones son similares a las estimaciones de  $\beta$  en el modelo SDM ( $-0.0007$ ,  $-0.0048$  y  $0.0042$ ) recogidos en la Tabla 2.6. La diferencia entre estas estimaciones representan el feedback que surge como resultado de los efectos que pasan por los países vecinos y regresan al propio país (Fischer y col. 2009; Elhorst 2012). Las estimaciones de los efectos directos en las variables consumo de energía vial y PIB son significativas indicando que variaciones en esas variables explicativas en un determinado país producen variaciones sobre el logaritmo de SMR en ese mismo país.

Respecto a los efectos indirectos, sólo la variable tasa de actividad es significativa y negativa, provocando que el efecto total sea significativo y negativo. Esto significa que el aumento de la tasa de actividad en un determinado país no sólo disminuirá el logaritmo del SMR en el propio país, sino también en el resto de países. Mientras que los efectos indirectos en el modelo no espacial son cero por construcción, el efecto indirecto de un cambio en las variables explicativas en el modelo SDM es un 6.05 del efecto directo en el caso de la variable tasa de actividad. Este ratio entre el efecto indirecto y el efecto directo, en el modelo SDM depende de los parámetros espaciales  $\lambda$ ,  $\delta$  y de la especificación de la matriz de pesos espaciales  $W_{ij}$  lo que hace dicho modelo sea más atractivo que otros modelos de regresión espacial en un estudio empírico (Elhorst 2010; Golgher y Voss 2016). Llama la atención que el signo de los efectos indirectos en las variables consumo de energía vial y PIB han cambiado con respecto al signo de los  $\beta$  en el modelo SDM (Tabla 2.6). Esto es debido a que el modelo SDM es más flexible, y por tanto, más adecuado para modelar los efectos indirectos (Elhorst 2014; Golgher y Voss 2016). Este hecho se vuelve a confirmar en el ejemplo que proporciona Elhorst (2014) para estimar la demanda de cigarrillos en USA.

Por todos los análisis anteriores, concluimos que el modelo finalmente seleccionado en Matlab es un Modelo Durbin Espacial con efecto fijo espacial y temporal. Es el modelo que mejor representa la dependencia espacial de los datos de mortalidad, tal y como indican las medidas de bondad de ajuste  $R^2$  y

**Tabla 2.9:** Estimaciones de efectos directos e indirectos basados en los coeficientes del SDM

Efecto	Variable	Coefficientes	t valores	p-valor
Directo	Tasa de actividad	-0.0017	-1.5308	0.1380
Indirecto	Tasa de actividad	-0.0103	-6.0031	0.0000 *
Total	Tasa de actividad	-0.0120	-5.7794	0.0000 *
Directo	Consumo de energía vial	-0.0047	-5.2799	0.0000 *
Indirecto	Consumo de energía vial	0.0013	0.6507	0.5210
Total	Consumo de energía vial	-0.0034	-1.3795	0.1795
Directo	PIB	0.0040	6.1058	0.0000 *
Indirecto	PIB	-0.0018	-1.2676	0.2162
Total	PIB	0.0022	1.3567	0.1866

\*p-valores <0.05 son significativos

$\sigma^2$ . El parámetro espacial  $\lambda$  es positivo y estadísticamente significativo indicando que, además de las contribuciones que las covariables realizan al logaritmo del SMR de un país su valor se incrementa en 35.22 % cuando en promedio el logaritmo de los valores del SMR correspondientes al entorno también aumentan. En cuanto al efecto spillover total, sólo en la variable tasa de actividad es significativa y negativa. Esto significa que el aumento de la tasa de actividad en el propio país disminuirá el logaritmo de SMR no sólo en su propio país, sino también la mortalidad en el resto de países.

#### *Modelo SLMSTFE obtenido en R*

La Tabla 2.10 muestra la estimación de parámetros del SLMSTFE con efecto fijo espacial y temporal, el error estándar, el estadístico t y los p-valores. En ella, se observa que tanto los parámetros  $\beta$  asociados a las tres variables como el parámetro espacial  $\lambda$  son significativos (p-valor <0.05). El  $\lambda$  es positivo (0.3465) y estadísticamente significativo indicando que, además de las contribuciones que las covariables realizan al logaritmo del SMR de un país su valor se incrementa en 34.65 % cuando en promedio el logaritmo de los valores del SMR correspondientes al entorno también aumentan. Las medidas de bondad de ajuste del modelo son la varianza residual y el coeficiente de determinación. Ambas medidas no se obtienen directamente en el output del modelo. La  $\sigma^2$  tiene un valor aparentemente muy pequeño 0.0014, el cual depende de las unidades de medida. El  $R^2$  se ha obtenido a partir del valor del  $\sigma^2$  y de la varianza total el cual obtiene un valor de 0.97. Ambas medidas indican que es un buen modelo.

**Tabla 2.10:** Resultado del SLMSTFE en R

Parámetros	Estimación	Error Estándar	t-valor	p-valor
$\alpha$	0.2896	0.0523	5.5337	0.0000 *
$\lambda$	0.3465	0.0391	8.8624	0.0000 *
$\beta_{PIB}$	0.0041	0.0006	6.9201	0.0000 *
$\beta_{tasa\ actividad}$	-0.0033	0.0009	-3.7814	0.0002 *
$\beta_{consumo\ energia\ vial}$	-0.0041	0.0008	-5.3165	0.0000 *

\*p-valores <0.05 son significativos

Los resultados de la estimación de los efectos fijos espaciales del SLMSTFE se muestran en la Tabla 2.11, la cual incluye el valor estimado de éstos  $\mu_i$ , el error estándar, el valor del estadístico t y su correspondiente p-valor. El valor  $\mu_i$  representa la desviación del país  $i$  respecto del intercepto  $\alpha$ . En general, las estimaciones de efectos espaciales con signo positivo representan a los países del este de Europa, los cuales tienen un alto SMR. Esto significa que las variables omitidas constantes en el tiempo afectan positivamente al logaritmo del SMR, en comparación con el promedio  $\alpha$ . Por contra, las estimaciones de efectos espaciales con signo negativo corresponden a los países del oeste de Europa, los cuales tienen un bajo SMR. Esto significa que las variables omitidas constantes en el tiempo afectan negativamente al logaritmo del SMR, en comparación con el promedio  $\alpha$ .

Los resultados de la estimación de los efectos fijos temporales del SLMSTFE se muestran en la Tabla 2.12, la cual incluye el valor estimado de éstos  $\nu_t$ , el error estándar, el valor del estadístico t y los p-valores correspondientes. El valor  $\nu_t$  representa la desviación del año  $t$  respecto al intercepto  $\alpha$ . Igual que pasaba en el SDM, aunque ningún  $\nu_t$  es significativo, no podemos excluirlos del modelo tal y como nos indicó la prueba LM en la Tabla 2.4.

Adicionalmente, estos  $\nu_t$  se representaron gráficamente en la Figura 2.2. En ella, se puede observar que los efectos temporales siguen una tendencia creciente excepto para el período 1994-1997. Esta evolución negativa coincide con la obtenida en la Figura 2.1, la cual recoge el colapso del la Unión Soviética (Vågerö 2010).

Para poder interpretar correctamente los coeficientes del SLMSTFE se han obtenido los efectos directos, indirectos y totales mediante la función `impacts` del paquete `splm` de Millo y Piras (2012). En dicha función se debe de especificar

**Tabla 2.11:** Estimación de los efectos espaciales del SLMSTFE en R


<b>País</b>	<b>Estimación</b>	<b>Error Estándar</b>	<b>t-valor</b>	<b>p-valor</b>
Austria	-0.1368	0.0534	-2.5632	0.0104 *
Bélgica	-0.1182	0.0462	-2.5564	0.0106 *
Bielorrusia	0.2724	0.0529	5.1495	0.0000 *
Suiza	-0.1821	0.0608	-2.9974	0.0027 *
República Checa	0.1167	0.0532	2.1946	0.0282 *
Alemania	-0.1025	0.0523	-1.9614	0.0498 *
Dinamarca	0.0349	0.0592	0.5886	0.5561
Estonia	0.1350	0.0551	2.4527	0.0142 *
España	-0.1978	0.0496	-3.9840	0.0000 *
Finlandia	-0.0673	0.0545	-1.2360	0.2164
Francia	-0.2256	0.0500	-4.5154	0.0000 *
Hungría	0.2044	0.0451	4.5344	0.0000 *
Irlanda	-0.0074	0.0541	-0.1371	0.8909
Italia	-0.2123	0.0452	-4.6915	0.0000 *
Lituania	0.1161	0.0544	2.1342	0.0328 *
Luxemburgo	0.0224	0.0564	0.3972	0.6912
Letonia	0.2544	0.0545	4.6665	0.0000 *
Países Bajos	-0.1217	0.0550	-2.2123	0.0269 *
Noruega	-0.1231	0.0575	-2.1433	0.0321 *
Polonia	0.0522	0.0511	1.0211	0.3072
Portugal	0.0381	0.0554	0.6889	0.4909
Suecia	-0.1727	0.0563	-3.0659	0.0022 *
Eslovenia	0.0213	0.0528	0.4042	0.6860
Eslovaquia	0.1271	0.0541	2.3502	0.0188 *
Ucrania	0.3612	0.0513	7.0437	0.0000 *
Reino Unido	-0.0887	0.0557	-1.5932	0.1111

\*p-valores <0.05 son significativos

**Tabla 2.12:** Estimación de los efectos temporales del SLMSTFE en R

<b>Año</b>	<b>Estimación</b>	<b>Error Estándar</b>	<b>t-valor</b>	<b>p-valor</b>
1990	-0.0074	0.0532	-0.1392	0.8893
1991	-0.0042	0.0528	-0.0800	0.9363
1992	0.0030	0.0525	0.0565	0.9549
1993	0.0081	0.0519	0.1551	0.8767
1994	-0.0010	0.0522	-0.0190	0.9849
1995	-0.0081	0.0522	-0.1541	0.8775
1996	-0.0134	0.0522	-0.2567	0.7974
1997	-0.0153	0.0528	-0.2900	0.7718
1998	-0.0060	0.0527	-0.1135	0.9096
1999	-0.0038	0.0526	-0.0720	0.9426
2000	-0.0089	0.0532	-0.1673	0.8672
2001	0.0003	0.0526	0.0054	0.9957
2002	0.0033	0.0527	0.0618	0.9507
2003	-0.0025	0.0529	-0.0464	0.9630
2004	-0.0032	0.0534	-0.0591	0.9529
2005	-0.0036	0.0535	-0.0676	0.9461
2006	0.0010	0.0541	0.0178	0.9858
2007	0.0042	0.0544	0.0770	0.9386
2008	0.0130	0.0535	0.2427	0.8083
2009	0.0446	0.0518	0.8615	0.3889

\*p-valores <0.05 son significativos



**Figura 2.2:** Representación gráfica de los efectos temporales del SLMSTFE.

el modelo SLMSTFE y la matriz de pesos espaciales. Los resultados de esta función, se recogen en la Tabla 2.13 la cual muestra las estimaciones, el valor del estadístico y el p-valor de los tres efectos basados en los parámetros estimados del modelo SLMSTFE.

Las estimaciones de efectos directos de las tres variables explicativas tienen los signos esperados. La tasa de actividad toma el valor de -0.0034, el consumo de energía vial -0.0042 y el PIB 0.0043. Igual que pasaba en el modelo SDM el valor de estos coeficientes son similares a los  $\beta$  estimados en el modelo SLMSTFE recogidos en la Tabla 2.10 (-0.0033, -0.0041 y 0.0041). La diferencia entre estas estimaciones representa los efectos de feedback que surgen como resultado de los efectos que pasan por los países vecinos y regresan al propio país (Fischer y col. 2009; Elhorst 2012). Las estimaciones de los efectos directos de las tres variables explicativas son significativas, indicando que variaciones en las tres variables explicativas en un determinado país producen variaciones sobre la variable dependiente en ese mismo país. A diferencia del modelo SDM sólo la variable tasa de actividad era significativa.

Respecto a las estimaciones de los efectos indirectos todos son significativos. El signo de estos efectos en las variables tasa de actividad y consumo de energía vial son negativos. Esto significa que aumentos de estas variables en un país disminuirán el logaritmo del SMR no sólo en su propio país, sino también en el resto de países. Por contra, un aumento del PIB tiene un efecto positivo y significativo sobre el logaritmo del SMR en el propio país (efecto directo 0.0043) y también lo tiene en el resto de países (efecto indirecto 0.0020). En este modelo, el ratio entre el efecto indirecto y el efecto directo tienen valores similares para las tres covariables tasa de actividad 0.4705, consumo de energía vial 0.4762 y PIB 0.4651. En el modelo SLMSTFEE, este ratio sólo depende del parámetro espacial  $\lambda$  y de la especificación de la matriz de pesos espaciales  $W_{ij}$ . Esta limitación, no se traslada al modelo SDM, la cual es una de las características interesantes de este modelo debido a que dicho ratio depende además del parámetro espacial  $\delta$ . En consecuencia, el SLMSTFE es demasiado rígido para modelar adecuadamente los efectos indirectos (Elhorst 2014; Golgher y Voss 2016) de forma en que todos los efectos directos e indirectos asociados a todas las covariables son significativos y mantienen el mismo signo que los parámetros  $\beta$  del modelo. Esto no ocurre en el modelo SDM donde sólo el efecto total de la variable tasa de actividad es significativo. Por lo tanto, los investigadores no deben descartar utilizar el modelo espacial Durbin, ya que no sólo los niveles de significación cuentan sino también la flexibilidad.



**Tabla 2.13:** Estimaciones de efectos directos e indirectos basados en los coeficientes del SLMSTFE

Efecto	Variable	Coefficientes	z-valor	p-valor
Directo	Tasa de actividad	-0.0034	-3.8633	0.0001 *
Indirecto	Tasa de actividad	-0.0016	-3.3874	0.0007 *
Total	Tasa de actividad	-0.0050	-3.8430	0.0001 *
Directo	Consumo de energía vial	-0.0042	-5.9235	0.0000 *
Indirecto	Consumo de energía vial	-0.0020	-4.2171	0.0000 *
Total	Consumo de energía vial	-0.0062	-3.8430	0.0000 *
Directo	PIB	0.0043	6.7740	0.0000 *
Indirecto	PIB	0.0020	4.2896	0.0000 *
Total	PIB	0.0063	6.1523	0.0000 *

\*p-valores <0.05 son significativos

Por todos los análisis anteriores, concluimos que el modelo finalmente seleccionado en R es un Modelo de efecto fijo espacial y temporal con retardo espacial. Es el modelo que mejor representa la dependencia espacial de los datos, tal y como indican las medidas de bondad de ajuste  $R^2$  y  $\sigma^2$ . El parámetro espacial  $\lambda$  es positivo y estadísticamente significativo indicando que, además de las contribuciones que las covariables realizan al logaritmo del SMR de un país su valor se incrementa en 34.65 % cuando en promedio el logaritmo de los valores del SMR correspondientes al entorno también aumentan. En cuanto al efecto spillover total, en las tres covariables es significativo. Esto significa que variaciones de estas covariables en un determinado país variará el logaritmo del SMR no sólo en el propio país, sino también la mortalidad en el resto de países.

## 2.4 Conclusiones

En este trabajo, se presenta la metodología estadística propuesta por Elhorst (2014) para seleccionar el mejor modelo espacial de datos de panel utilizando el software estadístico Matlab. Posteriormente, dicha metodología se implementa en R para su comparación con la anterior. A partir de ambos procedimientos puede deducirse el modelo espacial seleccionado debido a que tiene en cuenta la vecindad entre los países europeos. Estos modelos aprovechan la estructura del panel de datos para plantear el análisis de regresión, permitiendo a su vez, otras opciones de modelado de las que las series temporales y los estudios de corte transversal carecen (Hsiao 2014; Elhorst 2014).

La aplicación práctica llevada a cabo en este estudio parte de un panel de datos de mortalidad correspondientes a 26 países europeos durante el período 1990-2009. Para cuantificar la mortalidad en Europa se ha propuesto el ratio de mortalidad estandarizado (SMR). Este ratio es ampliamente utilizado en áreas como la epidemiología, demografía y la econometría. Se modeliza su logaritmo para corregir la asimetría y aproximar su distribución a la Normal. Así pues, el logaritmo del SMR es la variable dependiente en el modelo espacial. Antes de ajustar el modelo, se realizó un estudio de multicolinealidad, el cual reveló que las variables independientes que se debían considerar en el modelo eran la tasa bruta de natalidad, tasa de actividad, consumo de energía del sector vial y el PIB.

En cuanto a las principales conclusiones del ajuste y selección del modelo espacial de datos en panel fueron las siguientes:

Las dos medidas de bondad de ajuste  $R^2$  y  $\sigma^2$  confirmaron que se debía de desestimar una regresión OLS y por contra, estimar un modelo de datos de panel con efecto fijo espacial y temporal. Las covariables que fueron significativas para explicar el logaritmo del SMR fueron la tasa de actividad, consumo de energía del sector vial y el PIB. Una vez seleccionado un modelo de datos de panel se estudió su conversión a un modelo espacial. La prueba clásica LM concluyó que es significativo considerar la dependencia espacial de la variable dependiente en el modelo de datos de panel con efecto fijo espacial y temporal, convirtiéndolo así en un modelo espacial. Estos resultados fueron los mismos utilizando ambos softwares.

La prueba LR obtenida en Matlab concluyó que es significativo considerar el efecto fijo espacial y temporal en el modelo de datos de panel. Dicha prueba justificó la estimación de un modelo de datos de panel con efecto fijo espacial y temporal a los datos. La prueba LR no está implementada en R, por lo que en su lugar, se utilizó la prueba del LM de Breusch y Pagan (1980). El resultado de esta prueba confirmó nuevamente que el efecto espacial y temporal no podían ser excluidos del modelo.

A partir de los resultados de los dos pasos anteriores se confirmó que se debía de seleccionar un modelo de datos de panel con efecto fijo espacial y temporal con retardo espacial en la variable dependiente (SLMSTFE).

A continuación, se consideró el modelo SDM para analizar si es significativo incluir la dependencia espacial en las covariables. El SDM sólo se estimó en Matlab utilizando las rutinas de Elhorst (2014) pues dicho modelo no se puede obtener en R.

El siguiente paso fue estudiar si los efectos que se deben de incluir en el modelo debían de considerarse como fijos o aleatorios. El test de Hausman aplicado al modelo SDM en Matlab y al modelo SLMSTFE en R indicó que los efectos espaciales y temporales debían de considerarse fijos y no aleatorios.

Por todos los análisis anteriores, el mejor modelo espacial de datos en panel que se ha podido obtener con el software R fue un SLMSTFE mientras que en Matlab fue un SDM.

Los modelos seleccionados se validaron utilizando las medidas de bondad de ajuste  $R^2$  y  $\sigma^2$ . Estas medidas, indicaron que los modelos SLMSTFE y SDM son buenos, ya que, el coeficiente de determinación es cercano a 1 y la varianza residual es pequeña, comparada con la varianza de la variable dependiente, en ambos modelos.

En relación con el trabajo de otros autores, hay que destacar que hasta donde sabemos, aunque hay trabajos que estudian las diferencias de mortalidad en Europa, no hay ningún estudio espacial que modelice el ratio de mortalidad estandarizado mediante datos de panel. Además, tampoco se ha establecido una comparativa entre los softwares Matlab y R para seleccionar el mejor modelo espacial de datos de panel. Esto es importante debido a la creciente popularidad del software libre R en la investigación en relación con softwares comerciales.

Por otra parte, en la mayoría de los países del centro y oeste de Europa, la esperanza de vida está aumentando sobre todo gracias a un un gran crecimiento económico y descenso de las enfermedades cardiovasculares. Muchos estudios como Meslé (2004) y Vågerö (2010) abordan la conocida esperanza de vida, pero ninguno de ellos aplica una metodología espacial para modelizar la dependencia espacial en los países a través del tiempo.



# Grupos de mortalidad de países europeos por sexo y edad

*La mortalidad ha disminuido en los países de la Unión Europea (UE) durante el último siglo. A pesar de estas tendencias similares, todavía existen diferencias en los niveles de mortalidad entre los países del este y oeste de Europa. Existen muchos estudios que detectan las diferencias en la mortalidad en Europa, pero ninguno cuantifica estas diferencias por edad y sexo, comprobando a su vez su significación estadística. Así pues, el objetivo de este estudio es cuantificar la dinámica de la mortalidad en Europa y detectar clusters significativos de países europeos con mortalidad similar, aplicando una metodología espacio-temporal. Esta metodología tiene en cuenta dos factores: el tiempo y las relaciones de vecindad entre los países. Para cuantificar la mortalidad y realizar estudios comparativos entre los países europeos se utilizó el estadístico “Cifra Comparativa de Mortalidad” (CMF).*

*Los resultados de este estudio cuantifican las diferencias del CMF en los países europeos por edad y sexo y confirman que éstas son significativas. Principalmente se observan dos clusters significativos en personas mayores de 64 años: un grupo de alta mortalidad formado por países del este de Europa y otro grupo de baja mortalidad compuesto por países del oeste de Europa. Por contra, para edades inferiores o iguales a 64 sólo se observó un cluster significativo de alta mortalidad formado por los países del este. Además, se confirmó la interacción espacio-tiempo entre los 26 países europeos estudiados durante el período 1990-2012.*

### 3.1 Introducción

Una primera fase de transición de la mortalidad en Europa abarcó desde el siglo XVII hasta principios del XIX y se caracterizó por una caída e incluso desaparición de la crisis de mortalidad causada por las enfermedades infecciosas (la peste, la viruela y el tifus). El final del siglo XIX también se caracterizó por una disminución de la mortalidad en la mayor parte de Europa, debido principalmente a una disminución de enfermedades como la diarrea y la tuberculosis. Esto produjo una disminución de la mortalidad juvenil, seguida por una caída de la mortalidad infantil. Un tercer período comenzó después de la Segunda Guerra Mundial y duró hasta el año 1960; algunos autores lo relacionan con el descubrimiento y el uso de sulfonamidas y antibióticos (transición epidemiológica) (Cutler, Deaton y Lleras-Muney 2006). Así, a principios de los años sesenta, las esperanzas de vida europeas convergieron hacia un máximo que sólo Suecia lo alcanzó en ese momento (Meslé y Vallin 2002). A mitad de los años sesenta, la situación de convergencia cambió debido a los regímenes comunistas de los países del este de Europa. Estos países comunistas fueron atacados por crisis sanitarias, las cuales obstaculizaron su progreso aumentando así la mortalidad. Por contra, los países del oeste de Europa comenzaron a progresar debido a los nuevos avances en la atención de la salud, específicamente en el tratamiento de las enfermedades cardiovasculares. En 1989, con el colapso del muro de Berlín, la esperanza de vida aumentó en países como República Checa, Hungría, Polonia y Eslovaquia en respuesta al cambio político, social y económico. Desde 1989, la esperanza de vida en estos países ha continuado aumentando (Leon 2011). Pero otros países soviéticos como Rusia, Estonia, Letonia y Lituania han seguido un camino diferente, principalmente debido al colapso de la Unión Soviética. En 2008 la esperanza de vida en Rusia alcanzó el nivel que tenía hacía 40 años. A finales del 2008, el Ministerio de Salud de Rusia propuso un conjunto de objetivos ambiciosos para mejorar la salud, y así poder aumentar la esperanza de vida de cara al futuro (Leon 2011). Por lo tanto, los países europeos han estado experimentando una divergencia entre el este y oeste.

Es bien sabido que los países de Europa oriental tienen una tasa de mortalidad superior a la de el resto de países. Por ejemplo, Vaupel, Zhang y van Raalte (2011) estudiaron 40 países desarrollados y mostraron que los países del este de Europa tienen una esperanza de vida inferior a la de los otros países considerados. Además, otros autores como Mackenbach, Karanikolos y McKee (2013), concluyen que las tendencias de mortalidad en Europa oriental se ven afectadas por cuestiones económicas y sanitarias, además de la falta de aplicación de políticas sanitarias eficaces. Por otro lado, en la mayoría de los países

del centro y oeste de Europa, la esperanza de vida está aumentando, debido principalmente a una disminución de la mortalidad producida por enfermedades cardiovasculares y por el crecimiento económico (Meslé 2004). Muchos de los estudios mencionados anteriormente consideran la bien conocida esperanza de vida, pero ninguno de ellos, utiliza una metodología espacio-temporal para detectar diferencias significativas en la mortalidad entre países europeos, lo que confirmaría que los países y sus vecinos evolucionan conjuntamente con el tiempo.

Este estudio está motivado por el interés en las desigualdades entre los sistemas de salud de los diferentes países de la Unión Europea (Spinakis y col. 2011). El objetivo principal de este trabajo es cuantificar la dinámica de la mortalidad en Europa y detectar clusters significativos o grupos de países europeos por sexo y edad. Además, se estudia la interacción espacio-tiempo aplicando una metodología espacio-temporal, que tiene en cuenta dos factores: el tiempo y las relaciones de vecindad entre los países europeos. Así pues, la base de este trabajo radica en la capacidad de determinar previamente áreas de comportamiento diferenciadas que toman en cuenta la desigualdad en la mortalidad.

Este capítulo está estructurado de la siguiente manera. La Sección 3.2 comienza describiendo la base de los datos de los países seleccionados. La sección termina con una exposición de las medidas de mortalidad y la metodología espacio-temporal utilizada para detectar diferencias significativas en la mortalidad entre países: Cifra Comparativa de Mortalidad, índice de Moran global, índice de Moran local y Markov espacial. En la Sección 3.3 se presentan los principales resultados de este estudio espacio-temporal y finalmente, en la última sección, se muestran las conclusiones más importantes del estudio.

## 3.2 Materiales y métodos

### 3.2.1 Datos

Con el objetivo de detectar diferencias significativas en la mortalidad europea, cada país se consideró como unidad de análisis. Los datos de mortalidad se descargaron de la Human Mortality Database (2016) para los siguientes 26 países europeos: Austria, Bielorrusia, Bélgica, Dinamarca, Eslovaquia, Eslovenia, España, Finlandia, Francia, Hungría, Irlanda, Italia, Letonia, Lituania, Luxemburgo, Países Bajos, Noruega, Polonia, Portugal, Eslovaquia, Eslovenia, España, Suecia, Suiza, Reino Unido y Ucrania. Estos países tienen un intervalo

de tiempo común máximo de 1990 a 2012, para los grupos de edad de 0 a 110+ para hombres y mujeres.

Los datos de mortalidad de Grecia y Bulgaria no se consideraron, debido a que éstos no tienen información correspondiente a sus vecinos como Rumanía, Albania y Macedonia. Además, se decidió no forzar la estructura de vecindad de estos países.

Estos datos de mortalidad se descargaron de la HMD utilizando el nuevo paquete de R llamado `HMDHFDplus` de Riffe (2015), en concreto la función `readHMDweb`, y no con el paquete habitual llamado `demography` de Hyndman y col. (2014) con la función `hmd.mx`. Gracias a la función `readHMDweb` los datos de mortalidad se descargan de una forma más ordenada, facilitando el tratamiento de éstos. Los argumentos de esta función son:

- Código identificativo del país. Para saber los códigos de todos los países de la HMD escribir y ejecutar `getHMDcountries()`.
- Item. El producto estadístico que se desea descargar, en nuestro caso escribir “Deaths 1×1” para descargar el número de muertes y “Population” para la población.
- Nombre de usuario en la HMD. Para ello, el usuario debe registrarse en la HMD en el siguiente link: <http://www.mortality.org/mp/auth.pl>
- Contraseña de usuario en la HMD.

De esta forma, para cada país se obtuvo un objeto `data.frame` con 4 variables que son el año, edad, número de muertes y población y 2553 observaciones (23 años × 111 edades). Por contra, con la función `hmd.mx` para cada país se obtiene un objeto `lista` con 6 elementos que son el nombre del país, tipo de datos (en este caso mortalidad), año, edad, tasa de mortalidad y población. Con los datos en forma de lista es más complicado trabajar, pues los elementos edad y año son vectores y la tasa de mortalidad y la población son listas. Además, no se obtienen directamente las muertes observadas.

Para analizar el comportamiento de grupos de edad importantes, se consideraron los mismos grupos que el Fondo Monetario Internacional considera para el cálculo del ratio de dependencia (Li y col. 2012), el cual es una cantidad crucial para garantizar el pago de las pensiones del sistema público. El ratio de dependencia se define como el número de personas mayores de 64 años dividido entre el número de personas de edades comprendidas entre 15 y 64 años. Por lo tanto, los tres grupos de edad estudiados fueron:



- $g_1$ .- Personas de edades comprendidas entre 0 y 14 años.
- $g_2$ .- Personas de edades comprendidas entre 15 y 64 años.
- $g_3$ .- Personas de edades comprendidas entre 65 y 110+ años.

Además, estos tres grupos de edad se han estudiado por separado para ambos sexos.

Los análisis estadísticos se realizaron con el software R Core Team (2015) y algunos paquetes específicos: `devtools` (Wickham y Chang 2016), `HMDHFDplus` (Riffe 2015), `mapprools` (Bivand y Lewin-Koh 2016; Charpentier 2014), `spdep` (Bivand 2012; Charpentier 2014), `GeoXp` (Laurent, Ruiz-Gazen y Thomas-Agnan 2012), `rgdal` (Bivand, Keitt y Rowlingson 2015), `Gmisc` (Gordon 2016) y `RColorBrewer` (Neuwirth 2014).

### 3.2.2 Estadísticos

#### *Estadísticos para la comparación de la mortalidad*

Para poder comparar las tasas brutas de mortalidad de diferentes áreas geográficas, se requiere la estandarización de dichas tasas. La estandarización permite comparaciones libres de los efectos que producen las diferencias del número de individuos en los subgrupos de las poblaciones (Julious, Nicholl y George 2001). Esos grupos son definidos típicamente por la edad y el sexo. Además, se puede encontrar cierta dificultad al utilizar poblaciones artificiales como la población estándar europea, para la cual las muertes observadas no están disponibles. En ese caso, es muy importante estandarizar las tasas brutas de mortalidad para poder realizar comparaciones entre países. Existen dos métodos de estandarización: directo e indirecto, tal y como lo demuestran Fleiss, Levin y Paik (2013). El método directo produce la Cifra Comparativa de Mortalidad (CMF), sus siglas en inglés provienen de “Comparative Mortality Figure”. El método indirecto produce el Ratio de Mortalidad Estandarizada (SMR), sus siglas en inglés provienen de “Standardized Mortality Ratio”. A continuación, se definen ambos ratios.

El SMR es bien conocido en epidemiología como el ratio entre el número real de muertes en una población estudiada durante un período de tiempo determinado y el número de muertes que se esperarían en una población estudiada si las tasas de mortalidad específicas por edad fueran las de la población estándar (Hinde 1998). Este ratio se describió de forma detallada en la Sección 1.2.2, pero sin tener en cuenta las variables edad y sexo.

A continuación, el SMR incluyendo las variables edad y sexo se define como

$$SMR_{g,i,t,s} = \frac{O_{g,i,t,s}}{E_{g,i,t,s}} \quad \begin{array}{l} g \in \{g_1, g_2, g_3\}, \quad i \in \{1, \dots, N\}, \quad t \in \{1, \dots, T\} \\ \text{y } s \in \{\text{masculino, femenino}\} \end{array} \quad (3.1)$$

donde,

- $i$  son los países europeos con un total de  $N$ ;
- $t$  es el periodo de tiempo en un total de  $T$ , expresado en años;
- $O_{g,i,t,s}$  representa el número de muertes observadas en cada país europeo  $i$ , grupo de edad  $g$ , año  $t$  y sexo  $s$ ;
- $E_{g,i,t,s}$  son las muertes esperadas correspondientes, bajo la hipótesis de que cada país tiene la misma mortalidad que el conjunto de países europeos.

Si  $x$  es la edad de muerte, las muertes observadas  $O_{g,i,t,s}$  se obtienen como

$$O_{g,i,t,s} = \sum_{x \in g} d_{x,i,t,s} \quad \text{para } g \in \{g_1, g_2, g_3\}$$

donde  $d_{x,i,t,s}$  representa el número de muertes.

Las muertes esperadas  $E_{g,i,t,s}$  se expresan como

$$E_{g,i,t,s} = \sum_{x \in g} m_{x,t} p_{x,i,t,s}, \quad (3.2)$$

donde  $p_{x,i,t,s}$  es la población de estudio y  $m_{x,t}$  es la tasa de mortalidad de la población estándar, que en este estudio es el conjunto de países europeos para ambos sexos,

$$m_{x,t} = \frac{\sum_{i=1}^N \sum_s d_{x,i,t,s}}{\sum_{i=1}^N \sum_s p_{x,i,t,s}}.$$

Cabe recordar que si el SMR es mayor que 1, hay un número mayor de muertes de lo esperado, en este caso hay “exceso de muertes” en la población estudiada.

El CMF se calcula como el ratio del número de muertes que se esperaría en la población estándar si experimentara las tasas de mortalidad por edad de la población estudiada y el número real de muertes en la población estándar durante un período de tiempo especificado (Julious, Nicholl y George 2001). Su cálculo se expresa como

$$CMF_{g,i,t,s} = \frac{E_{g,i,t,s}}{O_{g,t}} \quad g \in \{g_1, g_2, g_3\}, \quad i \in \{1, \dots, N\}, \quad t \in \{1, \dots, T\}$$

$$\text{y } s \in \{\text{masculino}, \text{femenino}\} \quad (3.3)$$

donde  $E_{g,i,t,s}$  se define como las muertes esperadas correspondientes en el grupo de edad  $g$ , país  $i$ , en el año  $t$  y sexo  $s$  y  $O_{g,t}$  representa el número de muertes observadas en el conjunto de países europeos en el grupo de edad  $g$  para el año  $t$ .

Si  $x$  es la edad de muerte, las muertes esperadas  $E_{g,i,t,s}$  se obtienen como

$$E_{g,i,t,s} = \sum_{x \in g} m_{x,i,t,s} P_{x,t} \quad \text{para } g \in \{g_1, g_2, g_3\} \quad (3.4)$$

donde  $m_{x,i,t,s}$  es la tasa de mortalidad de la población estudiada y  $P_{x,t}$ , la población estándar.

La tasa de mortalidad de la población estudiada se expresa como

$$m_{x,i,t,s} = \frac{d_{x,i,t,s}}{p_{x,i,t,s}}.$$

donde  $d_{x,i,t,s}$  y  $p_{x,i,t,s}$  son el número de muertes y la población estudiada, respectivamente.

La población del conjunto de países europeos es  $P_{x,t}$ , o población estándar se puede obtener como

$$P_{x,t} = \sum_{i=1}^N \sum_s p_{x,i,t,s}$$

Las muertes observadas en Europa  $O_{g,t}$  para ambos sexos se calcula como

$$O_{g,t} = \sum_{i=1}^N \sum_{x \in g} \sum_s d_{x,i,t,s}$$

Si el CMF es mayor que 1, representa una experiencia de mortalidad desfavorable, de la misma manera que ocurre con el SMR.

Con el objetivo de comparar la mortalidad a través del tiempo para los diferentes países europeos, el CMF se ha utilizado en este estudio por dos razones:

- El mismo denominador se aplica en el cálculo del CMF, lo cual permite comparar la mortalidad por sexo para diferentes países a lo largo del tiempo.
- Las tasas de mortalidad específicas por edad están disponibles para cada país (Julious, Nicholl y George 2001) necesarias en la ecuación (3.4) pero no en la ecuación (3.2).

### *Índice de Moran Global*

El índice de Moran global (Moran 1950b; Moran 1950a) es una medida resumen de la intensidad de la autocorrelación espacial entre unidades territoriales. Este índice se definió en la Sección 1.2.2, pero sin tener en cuenta las variables edad y sexo.

A continuación, el índice de Moran global incluyendo las variables edad y sexo se define como

$$GM_{g,t,s} = \frac{N \sum_i \sum_j W_{ij} (CMF_{g,i,t,s} - \overline{CMF}_{g,t,s}) (CMF_{g,j,t,s} - \overline{CMF}_{g,t,s})}{\sum_i \sum_j W_{ij} \sum_i (CMF_{g,i,t,s} - \overline{CMF}_{g,t,s})^2} \quad (3.5)$$

donde,

- $CMF_{g,i,t,s}$  se definió en la ecuación (3.3);
- $\overline{CMF}_{g,t,s}$  es la media del CMF en todos los países para cada grupo de edad  $g$ , año  $t$  y sexo  $s$ ;
- $W_{ij}$  es la matriz de pesos espaciales.

Teniendo en cuenta la proximidad y las razones socioeconómicas, la matriz de pesos espaciales  $W_{ij}$  se modificó considerando Suecia y Noruega vecinos de Dinamarca y Francia vecino de Reino Unido.

En la ecuación (3.5), se puede observar que el  $GM_{g,t,s}$  es la pendiente de la recta de regresión entre el  $CMF_{g,i,t,s}$  y la media de sus vecinos.

Los resultados posibles de este índice son los siguientes:

- $GM_{g,t,s} > 0$ .- Valores positivos de este índice indican una autocorrelación espacial positiva en los 26 países europeos, es decir, el CMF de estos países y sus vecinos varían en la misma dirección.
- $GM_{g,t,s} < 0$ .- Valores negativos de este índice indican una autocorrelación espacial negativa en los 26 países europeos, es decir, el CMF de estos países y sus vecinos varían en distinta dirección.
- $GM_{g,t,s} = 0$ .- Valores del índice cercanos a cero indican la ausencia de autocorrelación espacial entre los 26 países europeos.

### Índice de Moran local

Anselin (1995) introdujo el concepto de Indicadores Locales de Asociación Espacial (LISA), sus siglas provienen del inglés “Local Indicators of Spatial Association”, una versión local del índice Moran global que proporciona información sobre la contribución de cada país al índice global. Este índice se definió en la Sección 1.2.2, pero sin tener en cuenta las variables edad y sexo.

A continuación, el índice de Moran local incluyendo las variables edad y sexo se define como

$$LM_{g,i,t,s} = \frac{(CMF_{g,i,t,s} - \overline{CMF}_{g,t,s})}{S^2(CMF_{g,t,s})} \sum_i \sum_j W_{ij} (CMF_{g,j,t,s} - \overline{CMF}_{g,t,s})$$

para  $g \in \{g_1, g_2, g_3\}$ ,  $i \in \{1, \dots, N\}$ ,  $j \in \{1, \dots, N\}$  y  $i \neq j$

donde  $S^2(CMF_{g,t,s})$  es la varianza del CMF en todos los países para cada grupo de edad  $g$ , año  $t$  y sexo  $s$ . El índice de Moran local permite la identificación de asociaciones espaciales locales significativas:

- Clusters espaciales.- Un valor positivo significativo del  $LM_{g,i,t,s}$  indica clusters de países con valores altos de CMF rodeados de vecinos con valores altos de CMF, denotados por HH o agrupaciones espaciales de países con valores bajos de CMF rodeados de vecinos con valores bajos de CMF, denotados por LL.
- Clusters outlier.- Un valor negativo significativo del  $LM_{g,i,t,s}$  indica una agrupación atípica de países con valores altos de CMF rodeados por vecinos con valores bajos de CMF, denotados por HL o agrupación outlier de países con valores bajos de CMF rodeados por vecinos con altos valores de CMF, denotados por LH.

Para obtener los p-valores del índice de Moran local basados en el número de vecinos de cada país, se utilizó la corrección de Bonferroni igual que en Capítulo 1. El método de Bonferroni es un test de comparaciones múltiples, el cual fija un nivel de significación  $\alpha$  que se divide entre el número medio de vecinos en cada test. Si el p-valor ajustado es mayor que 0.05 el país no pertenece a ningún cluster (Anselin 1995; Goovaerts y Jacquez 2005).

*Markov espacial*

Las técnicas anteriores nos permiten estudiar la autocorrelación espacial de una manera estática. El  $GM_{g,t,s}$  y  $LM_{g,i,t,s}$  se obtienen para secciones temporales de los datos y, por lo tanto, no permiten una investigación conjunta de su evolución espacio-temporal. Con el fin de determinar si existe interacción entre ellos, en los trabajos Rey (2001) y Rey (2014) se amplían los componentes del proceso introducidos por Quah (1993) para estudiar la evolución dinámica del ingreso regional. Siguiendo ese estudio, la distribución del CMF medido en  $N$  países dentro de 4 estados (HH,HL,LH,LL), en un periodo de tiempo se discretiza dando una distribución. La matriz de las probabilidades de transición  $P$  de dimensión  $4 \times 4$  está formada por las probabilidades a través de cada uno de los 4 estados de esta distribución.

$$P = \begin{pmatrix} p_{1,1} & p_{1,2} & p_{1,3} & p_{1,4} \\ p_{2,1} & p_{2,2} & p_{2,3} & p_{2,4} \\ p_{3,1} & p_{3,2} & p_{3,3} & p_{3,4} \\ p_{4,1} & p_{4,2} & p_{4,3} & p_{4,4} \end{pmatrix}$$

donde  $p_{l,m}$  es la probabilidad de que un país pase del estado  $l$  al estado  $m$  en un período dado, siendo  $l = 1, \dots, 4$  y  $m = 1, \dots, 4$ .

Suponiendo homogeneidad temporal, la estimación de máxima verosimilitud de las probabilidades de transición se obtienen como

$$\hat{p}_{l,m} = \frac{\nu_{l,m}}{\sum_m \nu_{l,m}}$$

donde  $\nu_{l,m}$  es el número observado de transiciones del estado  $l$  al estado  $m$ .

Los diferentes países europeos pueden clasificarse como H o L estados y el valor medio del  $CMF$  permite una clasificación de sus vecinos en uno de esos estados. A partir de los datos de mortalidad observados durante un período de tiempo 1990-2012, las matrices de transición  $P(i)$  y  $P(j)$  pueden estimarse por separado, cada una de dimensión  $2 \times 2$  donde  $i$  representa un país y  $j$  su vecino. Del mismo modo, la matriz de transición conjunta  $P(ij)$  de dimensión  $4 \times 4$  se puede estimar, de esta forma hay cuatro estados que describen la relación entre un país y sus vecinos. Bajo la hipótesis de independencia o falta de dinámica espacial,  $P(ij) = P(i) \otimes P(j)$  tiene que cumplirse, donde  $\otimes$  representa el producto Kronecker. Las estimaciones de las correspondientes matrices de transición y un  $\chi^2$  (Anderson y Goodman 1957) permiten comprobar la igual-

dad de ambas matrices. Su rechazo significa que la cadena de Markov asociada con la co-evolución país-entorno no es separable, lo que significa que existe interacción espacio-temporal.

### 3.3 Resultados

Dado lo extenso de los resultados y mapas obtenidos, sólo mostraremos los más representativos. Los lectores interesados en los mapas de todos los años pueden consultarlos en el Anexo C para personas con edades entre 0-14 años, Anexo D para personas con edades entre 15-64 años y Anexo E para personas con edades entre 65- más de 110 años.

Para cuantificar y estudiar hechos relevantes de la evolución anual del CMF en Europa por sexo y grupo de edad para el período 1990-2012, se elaboraron las Tablas 3.1-3.6. Éstas incluyen en columnas: el CMF de los países europeos para el período 1990-2012 cada tres años, el valor de la media, la desviación estándar (DE) y la variación relativa del CMF expresada en porcentaje (VR %). En las filas se incluyen: el nombre del país, la media del CMF para los países del oeste de Europa, países del este de Europa, países de la antigua Unión de Repúblicas Socialistas Soviéticas (URSS) y otros antiguos países comunistas. Las Tablas 3.1, 3.2 y 3.3 incluyen el CMF de los países europeos para los hombres y las Tablas 3.4, 3.5 y 3.6 la misma medida para las mujeres.

En promedio, el CMF de los países del este es elevado, ampliando la brecha entre estos países y los del oeste de Europa. Esta brecha es mayor en edades infantiles (0-14) y edades adultas (15-64). Para los hombres, la Tabla 3.1 muestra un CMF medio de 1.59 para Europa del este y 0.88 para Europa del oeste en edades infantiles y la Tabla 3.2 muestra un CMF medio de 2.49 para Europa del este y 1.01 para Europa del oeste en edades adultas. Para las mujeres ocurre lo mismo, la Tabla 3.4 muestra un CMF medio de 1.20 para Europa del este y 0.70 para Europa del oeste en edades infantiles y la Tabla 3.5 muestra un CMF medio de 0.87 para Europa del este y 0.51 para Europa del oeste en edades adultas. Esto significa una menor diferencia para las mujeres, en comparación con los hombres. Con respecto a la variabilidad del CMF, se encontró la misma tendencia. La desviación estándar del CMF es mayor en los países del este que en los del oeste, y es especialmente alta en las edades infantiles y adultas. Para hombres, la Tabla 3.1 indica 0.21 para los países del este y 0.09 para los países del oeste en edades infantiles y la Tabla 3.2 indica 0.25 para los países del este 0.06 para los países del oeste en edades adultas. Del mismo modo, para las mujeres la Tabla 3.4 indica 0.16 para los países del



este y 0.07 para los países del oeste en edades adultas y la Tabla 3.5 muestra 0.07 para los países del este y 0.02 para los países del oeste en edades adultas. Esto significa una menor diferencia para las mujeres, otra vez.

Centrándonos en los países del este de Europa, especialmente en Bielorrusia, Estonia, Letonia, Lituania y Ucrania (países de la ex Unión Soviética) tienen un CMF medio más alto que el resto de los países del este. La media del CMF es mayor para las edades infantiles y edades adultas, siendo una vez más mayor en los hombres. La Tabla 3.1 muestra 1.93 para los países de la antigua URSS y 1.24 para el resto de los países del este en edades infantiles y la Tabla 3.2 muestra 3.09 para los países de la antigua URSS y 1.89 para el resto de los países del este en edades adultas. Es importante destacar que la media del CMF de los países de la antigua URSS, especialmente para los hombres en la edades adultas, es más alto que el resto de Europa. Del mismo modo para las mujeres la Tabla 3.4 indica 1.42 para los países de la antigua URSS y 0.98 para el resto de los países del este en edades infantiles y la Tabla 3.5 indica 1 para los países de la antigua URSS y 0.73 para el resto de los países del este de edades adultas lo que significa una diferencia menor para las mujeres, de nuevo. Cabe destacar que, entre 1990 y 1994 se detectó un aumento en la media del CMF para los países de la antigua URSS tanto para hombres como para mujeres. Con respecto a la variabilidad del CMF, se encontró la misma tendencia. La desviación estándar es mayor en los países del este que en los del oeste, y es especialmente alta en edades infantiles y en edades adultas. Para los hombres, la Tabla 3.1 muestra 0.29 para los países de la antigua URSS y 0.15 para el resto de los países del este en edades infantiles y la Tabla 3.2 indica 0.42 para los países de la antigua URSS y 0.10 para el resto de los países del este en edades adultas. De la misma forma para las mujeres, la Tabla 3.4 muestra 0.21 para los países de la antigua URSS y 0.11 para el resto de los países del este en edades infantiles y la Tabla 3.5 muestra 0.11 para los países de la antigua URSS y 0.03 para el resto de los países del este en edades adultas. Esto significa una menor diferencia para las mujeres, en comparación con los hombres.

Para edades superiores a 64 años se observa un CMF más alto para los hombres que para las mujeres tanto en los países orientales como occidentales. Para los hombres, la Tabla 3.3 muestra 1.70 para el este de Europa y 1.21 para el oeste de Europa y para mujeres la Tabla 3.6 muestra 1.10 para el este y 0.77 para el oeste de Europa. En particular, la media del CMF es más alta en los países de la antigua Unión Soviética que para el resto de los países del este. En el caso de los hombres, la Tabla 3.3 muestra un 1.80 los países de la antigua URSS y un 1.61 para el resto de los países del este y para las mujeres la Tabla 3.6

muestra un 1.15 los países de la antigua URSS y 1.06 para el resto de los países del este.

Es importante destacar Eslovenia como el país del este de Europa con el CMF más bajo que la media del CMF de los países del este, para todos los grupos de edad y años considerados. La Tabla 3.1 muestra 0.86 para Eslovenia y 1.59 para los países del este en edades infantiles, la Tabla 3.2 muestra 1.46 para Eslovenia y 2.49 para los países del este en edades adultas y la Tabla 3.3 muestra 1.44 para Eslovenia y 1.70 para los países del este en la tercera edad. Del mismo modo para las mujeres, la Tabla 3.4 muestra 0.67 para Eslovenia y 1.20 para los países del este en edades infantiles, la Tabla 3.5 muestra 0.58 para Eslovenia y 0.87 para los países del este en edades adultas y la Tabla 3.6 muestra 0.90 para Eslovenia y 1.10 para los países del este en la tercera edad. De la misma manera, Ucrania es el país del este de Europa con el CMF más alto que la media del CMF de los países del este, para todos los años considerados y todos los grupos de edad. En media para los hombres, la Tabla 3.1 muestra un 2.41 para Ucrania y un 1.59 para los países del este en edades infantiles, la Tabla 3.2 muestra 3.41 para Ucrania y 2.49 para los países del este en edades adultas y la Tabla 3.3 muestra 1.98 para Ucrania y 1.70 para los países del este en la tercera edad. Del mismo modo para las mujeres, la Tabla 3.4 muestra un 1.76 para Ucrania y 1.20 para los países del este en las edades infantiles, la Tabla 3.5 muestra 1.15 para Ucrania y 0.87 para los países del este en las edades adultas y la Tabla 3.6 muestra 1.34 para Ucrania y 1.10 para los países del este en la tercera edad. Con respecto a los países del oeste de Europa, no hay ningún país que tenga un CMF más alto o más bajo que la media de los países occidentales para todos los años y grupos de edad.

Por último, cabe destacar que Portugal y Luxemburgo son los países del este de Europa que tienen el mayor decrecimiento del CMF<sup>F</sup> en edades infantiles, tal y como lo demuestra la variación relativa de -39.27 % y -30.03 % respectivamente en la Tabla 3.1 para hombres y para mujeres -19.13 % y -45.87 % en la Tabla 3.4.

Tabla 3.1 Comportamiento del CMF en los países europeos para hombres entre 0 y 14 años durante el período 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR %
Oeste	Austria	0.88	0.86	0.79	0.76	0.87	0.90	0.93	1.03	0.88	0.07	-3.11
Oeste	Bélgica	0.95	1.01	0.87	0.94	0.96	0.93	0.94	0.98	0.95	0.06	17.95
Oeste	Dinamarca	0.95	0.74	0.87	0.85	0.95	0.95	0.97	0.80	0.87	0.08	-14.51
Oeste	Finlandia	0.68	0.65	0.68	0.73	0.67	0.91	0.78	0.72	0.71	0.07	-3.28
Oeste	Francia	0.88	0.88	0.82	0.84	0.87	0.85	0.88	0.89	0.88	0.04	6.66
Oeste	Alemania	0.89	0.80	0.80	0.83	0.81	0.87	0.85	0.95	0.85	0.05	1.70
Oeste	Irlanda	0.93	0.93	0.94	1.11	1.04	0.77	1.03	0.91	0.95	0.11	-11.78
Oeste	Italia	0.88	0.81	0.90	0.86	0.92	0.80	0.84	0.82	0.85	0.06	-11.18
Oeste	Luxemburgo	0.81	1.17	0.88	0.98	1.49	0.64	0.61	1.08	0.87	0.24	-30.03
Oeste	P. Bajos	0.88	0.85	0.87	0.92	1.00	1.01	0.86	0.97	0.92	0.07	15.64
Oeste	Noruega	0.91	0.73	0.72	0.80	0.75	0.79	0.76	0.73	0.76	0.05	-18.95
Oeste	Portugal	1.42	1.38	1.30	1.20	1.19	0.90	0.85	0.95	1.13	0.22	-39.27
Oeste	España	0.91	0.89	0.92	0.86	0.90	0.90	0.86	0.83	0.87	0.04	-10.14
Oeste	Suecia	0.71	0.66	0.56	0.67	0.68	0.65	0.59	0.61	0.66	0.05	6.12
Oeste	Suiza	0.82	0.74	0.79	0.89	0.89	0.98	0.90	0.99	0.87	0.07	10.06
Oeste	Reino Unido	0.92	0.83	0.90	0.98	1.03	1.08	1.09	1.14	0.99	0.10	18.90
<b>Media países del oeste</b>		<b>0.90</b>	<b>0.87</b>	<b>0.85</b>	<b>0.89</b>	<b>0.93</b>	<b>0.87</b>	<b>0.86</b>	<b>0.90</b>	<b>0.88</b>	<b>0.09</b>	<b>-5.40</b>
Este	Bielorrusia*	1.48	1.72	1.98	2.32	1.96	1.94	1.42	1.39	1.78	0.28	-13.41
Este	R. Checa	1.22	1.13	0.91	0.89	0.95	0.89	0.83	0.78	0.96	0.13	-32.25
Este	Estonia*	1.77	1.92	1.75	1.85	1.62	1.38	1.45	0.94	1.62	0.39	-47.24
Este	Hungría	1.56	1.45	1.38	1.48	1.39	1.43	1.33	1.21	1.41	0.13	-21.71
Este	Letonia*	1.98	2.20	2.22	2.04	2.31	2.05	1.94	1.86	2.12	0.25	-14.48
Este	Lituania*	1.44	1.95	1.54	1.71	1.76	1.95	1.65	1.52	1.72	0.20	-11.60
Este	Polonia	1.93	1.78	1.65	1.47	1.40	1.37	1.35	1.21	1.49	0.21	-35.25
Este	Eslovaquia	1.33	1.34	1.44	1.49	1.34	1.60	1.55	1.50	1.48	0.09	16.76
Este	Eslovenia	1.03	0.92	0.88	0.92	0.95	0.93	0.73	0.88	0.86	0.14	-47.75
Este	Ucrania*	1.70	2.15	2.39	2.49	2.71	2.60	2.63	2.54	2.41	0.28	45.85
<b>Media países del este</b>		<b>1.55</b>	<b>1.66</b>	<b>1.61</b>	<b>1.67</b>	<b>1.64</b>	<b>1.61</b>	<b>1.49</b>	<b>1.38</b>	<b>1.59</b>	<b>0.21</b>	<b>-15.49</b>
<b>Media países USSR</b>		<b>1.68</b>	<b>1.99</b>	<b>1.98</b>	<b>2.08</b>	<b>2.07</b>	<b>1.98</b>	<b>1.82</b>	<b>1.65</b>	<b>1.93</b>	<b>0.29</b>	<b>-8.51</b>
<b>Media otros países comunistas</b>		<b>1.42</b>	<b>1.32</b>	<b>1.25</b>	<b>1.25</b>	<b>1.21</b>	<b>1.24</b>	<b>1.16</b>	<b>1.12</b>	<b>1.24</b>	<b>0.15</b>	<b>-23.76</b>

\*países de la antigua URSS.

**Tabla 3.2** Comportamiento del CMF en los países europeos para hombres entre 15 y 64 años durante el periodo 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR %
Oeste	Austria	1.23	1.17	1.11	1.07	1.03	1.00	0.97	1.06	1.08	0.07	-14.18
Oeste	Bélgica	1.09	1.05	1.03	1.08	1.07	1.04	1.08	1.09	1.06	0.02	1.68
Oeste	Dinamarca	1.23	1.16	1.14	1.09	1.09	1.02	1.04	1.04	1.11	0.05	-16.39
Oeste	Finlandia	1.44	1.25	1.19	1.23	1.15	1.24	1.22	1.21	1.23	0.07	-18.75
Oeste	Francia	1.27	1.22	1.16	1.14	1.15	1.11	1.10	1.17	1.16	0.04	-7.64
Oeste	Alemania	1.26	1.18	1.13	1.07	1.05	1.01	1.01	1.09	1.09	0.07	-13.16
Oeste	Irlanda	1.12	1.06	1.02	1.05	1.00	0.85	0.87	0.92	0.98	0.08	-17.73
Oeste	Italia	1.04	0.95	0.91	0.88	0.83	0.77	0.79	0.79	0.86	0.09	-23.17
Oeste	Luxemburgo	1.21	1.15	1.18	1.05	1.10	1.01	0.87	0.96	1.08	0.10	-18.19
Oeste	P.Bajos	0.94	0.92	0.87	0.88	0.86	0.79	0.77	0.78	0.85	0.05	-13.96
Oeste	Noruega	1.01	0.93	0.85	0.87	0.87	0.80	0.79	0.84	0.87	0.06	-17.84
Oeste	Portugal	1.34	1.32	1.32	1.30	1.25	1.22	1.16	1.22	1.26	0.05	-9.29
Oeste	España	1.09	1.05	1.03	1.00	1.00	0.96	0.92	0.93	1.00	0.05	-14.52
Oeste	Suecia	0.89	0.81	0.76	0.76	0.75	0.73	0.73	0.75	0.77	0.05	-15.46
Oeste	Suiza	0.99	0.91	0.84	0.82	0.80	0.76	0.72	0.74	0.82	0.08	-23.57
Oeste	Reino Unido	1.06	0.99	0.95	0.96	0.94	0.90	0.91	0.92	0.95	0.04	-13.91
<b>Media países del oeste</b>		<b>1.14</b>	<b>1.07</b>	<b>1.03</b>	<b>1.01</b>	<b>0.99</b>	<b>0.95</b>	<b>0.94</b>	<b>0.97</b>	<b>1.01</b>	<b>0.06</b>	<b>-14.62</b>
Este	Bielorrusia*	2.24	2.76	3.03	3.47	3.77	3.83	3.64	4.10	3.34	0.53	56.40
Este	R.Checa	1.90	1.63	1.57	1.56	1.52	1.47	1.45	1.50	1.56	0.11	-22.52
Este	Estonia*	2.45	2.97	2.74	2.83	2.88	2.62	2.47	2.26	2.72	0.30	-6.34
Este	Hungría	2.46	2.65	2.42	2.56	2.37	2.45	2.37	2.43	2.46	0.09	-5.52
Este	Letonia*	2.56	3.46	3.02	3.02	3.09	3.23	3.01	2.83	3.09	0.32	12.32
Este	Lituania*	2.25	2.88	2.76	2.56	2.77	3.22	3.33	3.12	2.89	0.35	38.40
Este	Polonia	2.11	1.98	1.94	2.04	1.86	1.93	2.01	2.04	2.00	0.08	-2.21
Este	Eslovaquia	2.20	1.95	1.84	2.00	1.97	1.95	1.97	1.97	1.97	0.08	-11.88
Este	Eslovenia	1.63	1.70	1.47	1.50	1.47	1.31	1.28	1.23	1.46	0.14	-22.58
Este	Ucrania*	2.29	2.75	3.33	3.32	3.66	4.12	4.18	3.44	3.41	0.53	52.69
<b>Media países del este</b>		<b>2.21</b>	<b>2.47</b>	<b>2.41</b>	<b>2.49</b>	<b>2.54</b>	<b>2.61</b>	<b>2.57</b>	<b>2.49</b>	<b>2.49</b>	<b>0.25</b>	<b>10.21</b>
<b>Media países de la antigua URSS</b>		<b>2.36</b>	<b>2.96</b>	<b>2.98</b>	<b>3.04</b>	<b>3.24</b>	<b>3.40</b>	<b>3.33</b>	<b>3.15</b>	<b>3.09</b>	<b>0.42</b>	<b>29.63</b>
<b>Media otros países comunistas</b>		<b>2.06</b>	<b>1.98</b>	<b>1.85</b>	<b>1.93</b>	<b>1.84</b>	<b>1.82</b>	<b>1.82</b>	<b>1.83</b>	<b>1.89</b>	<b>0.10</b>	<b>-12.04</b>

\*países de la antigua URSS.

Tabla 3.3 Comportamiento del CMF en los países de Europa para hombres entre 65 y 110+ edades durante el período 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR
Oeste	Austria	1.28	1.26	1.25	1.22	1.20	1.17	1.17	1.19	1.22	0.04	-7.06
Oeste	Bélgica	1.29	1.29	1.27	1.26	1.28	1.24	1.23	1.22	1.26	0.02	-3.61
Oeste	Dinamarca	1.30	1.32	1.32	1.30	1.32	1.28	1.29	1.28	1.30	0.03	-3.91
Oeste	Finlandia	1.37	1.35	1.31	1.29	1.28	1.20	1.18	1.25	1.28	0.05	-10.01
Oeste	Francia	1.10	1.07	1.09	1.09	1.08	1.06	1.05	1.04	1.07	0.02	-4.98
Oeste	Alemania	1.35	1.30	1.30	1.26	1.25	1.23	1.24	1.25	1.27	0.03	-8.49
Oeste	Irlanda	1.45	1.46	1.46	1.50	1.36	1.23	1.23	1.21	1.36	0.10	-16.19
Oeste	Italia	1.17	1.13	1.12	1.13	1.11	1.10	1.11	1.13	1.13	0.02	-3.37
Oeste	Luxemburgo	1.30	1.32	1.32	1.30	1.26	1.21	1.20	1.26	1.28	0.05	-9.35
Oeste	P.Bajos	1.26	1.30	1.30	1.30	1.31	1.27	1.22	1.21	1.27	0.03	-3.33
Oeste	Noruega	1.23	1.24	1.18	1.22	1.22	1.15	1.18	1.18	1.19	0.03	-5.86
Oeste	Portugal	1.32	1.32	1.30	1.30	1.29	1.30	1.25	1.23	1.28	0.02	-4.43
Oeste	España	1.11	1.07	1.08	1.13	1.10	1.13	1.10	1.09	1.10	0.02	-1.05
Oeste	Suecia	1.14	1.14	1.11	1.11	1.13	1.12	1.12	1.14	1.12	0.01	-0.37
Oeste	Suiza	1.14	1.08	1.07	1.07	1.04	1.04	1.02	1.05	1.06	0.03	-9.43
Oeste	Reino Unido	1.31	1.32	1.28	1.27	1.23	1.18	1.17	1.12	1.23	0.07	-14.59
<b>Media países del oeste</b>		<b>1.26</b>	<b>1.25</b>	<b>1.24</b>	<b>1.23</b>	<b>1.22</b>	<b>1.18</b>	<b>1.17</b>	<b>1.18</b>	<b>1.21</b>	<b>0.04</b>	<b>-6.85</b>
Este	Bielorrusia*	1.46	1.67	1.78	1.95	2.09	2.11	2.11	2.19	1.94	0.23	46.42
Este	R.Checa	1.80	1.64	1.60	1.57	1.59	1.59	1.53	1.58	1.61	0.07	-13.48
Este	Estonia*	1.64	1.75	1.67	1.67	1.69	1.74	1.73	1.64	1.70	0.05	-0.83
Este	Hungría	1.68	1.70	1.69	1.73	1.68	1.76	1.73	1.75	1.71	0.03	3.02
Este	Letonia*	1.63	1.78	1.74	1.69	1.81	1.93	1.94	1.86	1.80	0.10	12.85
Este	Lituania*	1.36	1.52	1.50	1.49	1.59	1.66	1.70	1.74	1.58	0.12	24.70
Este	Polonia	1.59	1.60	1.61	1.60	1.54	1.54	1.56	1.54	1.57	0.03	-3.36
Este	Eslovaquia	1.67	1.64	1.63	1.66	1.68	1.76	1.77	1.73	1.71	0.06	2.61
Este	Eslovenia	1.45	1.52	1.44	1.47	1.47	1.45	1.35	1.37	1.44	0.05	-7.45
Este	Ucrania*	1.57	1.80	1.92	1.91	2.05	2.16	2.15	2.11	1.98	0.18	30.96
<b>Media países del este</b>		<b>1.58</b>	<b>1.66</b>	<b>1.66</b>	<b>1.67</b>	<b>1.72</b>	<b>1.77</b>	<b>1.76</b>	<b>1.75</b>	<b>1.70</b>	<b>0.09</b>	<b>8.73</b>
<b>Media países de la antigua URSS</b>		<b>1.53</b>	<b>1.70</b>	<b>1.72</b>	<b>1.74</b>	<b>1.85</b>	<b>1.92</b>	<b>1.93</b>	<b>1.91</b>	<b>1.80</b>	<b>0.15</b>	<b>22.13</b>
<b>Media otros países comunistas</b>		<b>1.64</b>	<b>1.62</b>	<b>1.59</b>	<b>1.60</b>	<b>1.59</b>	<b>1.62</b>	<b>1.59</b>	<b>1.60</b>	<b>1.61</b>	<b>0.05</b>	<b>-3.78</b>

\*países de la antigua URSS.

**Tabla 3.4** Comportamiento del CMF en países europeos para mujeres entre 0 y 14 años durante el período 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR
Oeste	Austria	0.71	0.71	0.65	0.67	0.63	0.80	0.66	0.69	0.71	0.07	12.55
Oeste	Bélgica	0.73	0.71	0.64	0.70	0.72	0.74	0.75	0.80	0.74	0.04	12.88
Oeste	Dinamarca	0.68	0.62	0.68	0.58	0.71	0.67	0.72	0.80	0.69	0.06	11.18
Oeste	Finlandia	0.58	0.47	0.53	0.63	0.53	0.77	0.53	0.60	0.57	0.07	17.51
Oeste	Francia	0.65	0.63	0.60	0.66	0.69	0.67	0.74	0.74	0.68	0.05	19.15
Oeste	Alemania	0.67	0.61	0.62	0.65	0.70	0.71	0.69	0.79	0.67	0.05	10.54
Oeste	Irlanda	0.69	0.63	0.72	0.90	0.87	0.85	0.74	0.69	0.75	0.10	14.92
Oeste	Italia	0.68	0.76	0.79	0.71	0.71	0.65	0.69	0.68	0.70	0.04	2.65
Oeste	Luxemburgo	0.89	0.61	0.80	0.60	0.72	0.75	0.59	0.63	0.70	0.15	-45.87
Oeste	P. Bajos	0.68	0.65	0.69	0.78	0.78	0.86	0.77	0.71	0.73	0.07	15.32
Oeste	Noruega	0.63	0.56	0.49	0.63	0.74	0.59	0.54	0.52	0.60	0.06	2.68
Oeste	Portugal	1.05	0.98	1.00	0.99	0.97	0.74	0.76	0.65	0.89	0.14	-19.13
Oeste	España	0.72	0.70	0.68	0.70	0.70	0.69	0.70	0.72	0.70	0.02	-3.95
Oeste	Suecia	0.56	0.50	0.47	0.47	0.55	0.53	0.56	0.54	0.53	0.05	7.26
Oeste	Suiza	0.66	0.67	0.60	0.65	0.71	0.69	0.73	0.83	0.71	0.09	24.25
Oeste	Reino Unido	0.69	0.65	0.70	0.77	0.78	0.86	0.89	0.86	0.79	0.10	24.31
<b>Media países del oeste</b>		<b>0.70</b>	<b>0.65</b>	<b>0.67</b>	<b>0.69</b>	<b>0.72</b>	<b>0.72</b>	<b>0.69</b>	<b>0.70</b>	<b>0.70</b>	<b>0.07</b>	<b>4.72</b>
Este	Bielorrusia*	1.06	1.18	1.44	1.54	1.43	1.29	0.95	0.99	1.26	0.18	-10.28
Este	R. Checa	0.88	0.82	0.77	0.74	0.73	0.70	0.58	0.61	0.73	0.09	-27.34
Este	Estonia*	1.18	1.48	1.30	1.53	0.92	1.27	0.95	0.75	1.20	0.26	-22.25
Este	Hungría	1.24	1.16	1.22	1.09	1.19	1.07	1.06	1.09	1.15	0.07	-4.73
Este	Letonia*	1.24	1.59	1.80	1.88	1.75	1.59	1.16	1.40	1.62	0.21	8.68
Este	Lituania*	1.08	1.40	1.34	1.40	1.28	1.21	1.32	1.09	1.29	0.16	-13.25
Este	Polonia	1.47	1.38	1.30	1.13	1.10	1.14	1.07	0.98	1.18	0.15	-31.93
Este	Eslovaquia	1.00	1.00	1.14	1.18	1.35	1.20	1.12	1.13	1.15	0.12	13.07
Este	Eslovenia	0.67	0.67	0.51	0.61	0.56	0.87	0.58	0.65	0.67	0.11	-22.98
Este	Ucrania*	1.18	1.49	1.74	1.78	1.83	1.89	2.05	1.95	1.76	0.22	65.12
<b>Media países del este</b>		<b>1.10</b>	<b>1.22</b>	<b>1.26</b>	<b>1.29</b>	<b>1.21</b>	<b>1.22</b>	<b>1.08</b>	<b>1.06</b>	<b>1.20</b>	<b>0.16</b>	<b>-3.87</b>
<b>Media países de la antigua URSS</b>		<b>1.15</b>	<b>1.43</b>	<b>1.52</b>	<b>1.63</b>	<b>1.44</b>	<b>1.45</b>	<b>1.29</b>	<b>1.24</b>	<b>1.42</b>	<b>0.21</b>	<b>6.29</b>
<b>Media otros países comunistas</b>		<b>1.05</b>	<b>1.00</b>	<b>0.99</b>	<b>0.95</b>	<b>0.99</b>	<b>1.00</b>	<b>0.88</b>	<b>0.89</b>	<b>0.98</b>	<b>0.11</b>	<b>-14.96</b>

\*países de la antigua URSS.

Tabla 3.5 Comportamiento del CMF en los países europeos para mujeres entre 15 y 64 años durante el período 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR
Oeste	Austria	0.54	0.53	0.50	0.51	0.48	0.48	0.47	0.53	0.50	0.02	-2.75
Oeste	Bélgica	0.54	0.51	0.51	0.53	0.55	0.55	0.57	0.62	0.55	0.03	12.86
Oeste	Dinamarca	0.76	0.73	0.71	0.71	0.67	0.64	0.64	0.64	0.68	0.04	-15.61
Oeste	Finlandia	0.52	0.49	0.45	0.48	0.50	0.54	0.52	0.53	0.50	0.03	2.82
Oeste	Francia	0.49	0.48	0.47	0.48	0.48	0.48	0.49	0.53	0.49	0.02	9.19
Oeste	Alemania	0.58	0.54	0.53	0.51	0.51	0.50	0.52	0.58	0.53	0.02	-1.81
Oeste	Irlanda	0.63	0.58	0.54	0.58	0.53	0.52	0.54	0.56	0.56	0.03	-11.10
Oeste	Italia	0.46	0.43	0.42	0.41	0.41	0.39	0.40	0.43	0.42	0.02	-4.52
Oeste	Luxemburgo	0.63	0.55	0.56	0.52	0.55	0.49	0.50	0.57	0.55	0.04	-15.83
Oeste	P. Bajos	0.50	0.51	0.51	0.55	0.57	0.54	0.55	0.58	0.54	0.03	17.65
Oeste	Noruega	0.50	0.47	0.48	0.50	0.51	0.50	0.48	0.52	0.49	0.02	-0.05
Oeste	Portugal	0.57	0.56	0.53	0.53	0.52	0.50	0.47	0.50	0.52	0.03	-14.04
Oeste	España	0.43	0.40	0.39	0.38	0.39	0.38	0.39	0.41	0.40	0.01	-4.59
Oeste	Suecia	0.48	0.45	0.44	0.46	0.45	0.46	0.45	0.47	0.46	0.01	-0.03
Oeste	Suiza	0.46	0.44	0.42	0.42	0.43	0.41	0.41	0.43	0.43	0.01	-4.20
Oeste	Reino Unido	0.62	0.58	0.55	0.57	0.56	0.55	0.57	0.59	0.57	0.02	-4.62
<b>Media países del oeste</b>		<b>0.54</b>	<b>0.52</b>	<b>0.50</b>	<b>0.51</b>	<b>0.51</b>	<b>0.50</b>	<b>0.50</b>	<b>0.53</b>	<b>0.51</b>	<b>0.02</b>	<b>-3.03</b>
Este	Bielorrusia*	0.79	0.91	0.98	1.11	1.18	1.17	1.10	1.24	1.05	0.13	34.99
Este	R. Checa	0.74	0.68	0.63	0.63	0.63	0.64	0.63	0.65	0.65	0.03	-11.69
Este	Estonia*	0.83	0.94	0.87	0.94	0.90	0.83	0.80	0.73	0.87	0.09	-11.61
Este	Hungría	0.99	1.03	0.92	0.98	0.93	0.94	0.95	1.02	0.97	0.03	0.68
Este	Letonia*	0.87	1.07	0.98	1.02	0.98	1.02	1.00	1.00	1.02	0.09	11.19
Este	Lituania*	0.79	0.90	0.90	0.84	0.86	0.96	1.08	1.00	0.92	0.09	22.75
Este	Polonia	0.77	0.72	0.70	0.73	0.68	0.71	0.74	0.76	0.73	0.03	0.55
Este	Eslovaquia	0.79	0.72	0.67	0.72	0.70	0.71	0.71	0.75	0.72	0.03	-3.65
Este	Eslovenia	0.60	0.66	0.61	0.62	0.57	0.56	0.51	0.55	0.58	0.04	-6.42
Este	Ucrania*	0.83	0.97	1.12	1.12	1.19	1.34	1.36	1.19	1.15	0.15	45.99
<b>Media países del este</b>		<b>0.80</b>	<b>0.86</b>	<b>0.84</b>	<b>0.87</b>	<b>0.86</b>	<b>0.89</b>	<b>0.89</b>	<b>0.89</b>	<b>0.87</b>	<b>0.07</b>	<b>8.74</b>
<b>Media países de la antigua URSS</b>		<b>0.82</b>	<b>0.96</b>	<b>0.97</b>	<b>1.00</b>	<b>1.02</b>	<b>1.06</b>	<b>1.07</b>	<b>1.03</b>	<b>1.00</b>	<b>0.11</b>	<b>20.47</b>
<b>Media otros países comunistas</b>		<b>0.78</b>	<b>0.76</b>	<b>0.71</b>	<b>0.74</b>	<b>0.70</b>	<b>0.71</b>	<b>0.71</b>	<b>0.74</b>	<b>0.73</b>	<b>0.03</b>	<b>-3.68</b>

\*países de la antigua URSS.

**Tabla 3.6** Comportamiento del CMF en los países europeos para las mujeres entre 65 y 110+ edades durante el período 1990-2012

Este/Oeste	País	1990	1993	1996	1999	2002	2005	2008	2011	Media	DE	VR
Oeste	Austria	0.84	0.81	0.81	0.79	0.78	0.77	0.77	0.78	0.79	0.02	-3.54
Oeste	Bélgica	0.76	0.75	0.75	0.75	0.77	0.77	0.78	0.79	0.77	0.02	5.95
Oeste	Dinamarca	0.81	0.86	0.86	0.87	0.91	0.87	0.89	0.89	0.87	0.03	8.32
Oeste	Finlandia	0.85	0.86	0.81	0.79	0.80	0.73	0.75	0.77	0.79	0.04	-8.62
Oeste	Francia	0.63	0.61	0.61	0.61	0.62	0.60	0.60	0.61	0.61	0.01	-0.64
Oeste	Alemania	0.87	0.82	0.81	0.78	0.79	0.79	0.81	0.83	0.81	0.02	-4.24
Oeste	Irlanda	0.91	0.93	0.93	0.96	0.89	0.82	0.83	0.83	0.89	0.05	-9.51
Oeste	Italia	0.73	0.70	0.68	0.69	0.67	0.67	0.69	0.71	0.69	0.02	-0.96
Oeste	Luxemburgo	0.83	0.82	0.80	0.80	0.78	0.78	0.79	0.80	0.81	0.03	-2.20
Oeste	P. Bajos	0.72	0.75	0.76	0.79	0.82	0.79	0.80	0.81	0.78	0.03	14.34
Oeste	Noruega	0.75	0.76	0.72	0.75	0.78	0.72	0.76	0.78	0.75	0.02	6.11
Oeste	Portugal	0.89	0.86	0.85	0.85	0.82	0.83	0.80	0.79	0.83	0.03	-9.24
Oeste	España	0.71	0.67	0.66	0.69	0.66	0.68	0.67	0.66	0.67	0.01	-4.74
Oeste	Suecia	0.71	0.72	0.70	0.71	0.75	0.73	0.76	0.78	0.73	0.03	11.88
Oeste	Suiza	0.68	0.64	0.65	0.66	0.66	0.65	0.67	0.69	0.66	0.02	3.38
Oeste	Reino Unido	0.81	0.83	0.82	0.84	0.83	0.82	0.83	0.80	0.82	0.01	1.37
<b>Media países del oeste</b>		<b>0.78</b>	<b>0.77</b>	<b>0.76</b>	<b>0.77</b>	<b>0.77</b>	<b>0.75</b>	<b>0.76</b>	<b>0.77</b>	<b>0.77</b>	<b>0.02</b>	<b>0.06</b>
Este	Bielorrusia*	0.97	1.10	1.16	1.26	1.32	1.31	1.29	1.31	1.22	0.11	30.80
Este	R. Checa	1.18	1.10	1.08	1.08	1.08	1.09	1.04	1.08	1.09	0.03	-9.52
Este	Estonia*	1.07	1.12	1.05	1.02	1.05	1.01	1.00	0.96	1.04	0.05	-12.85
Este	Hungría	1.14	1.13	1.15	1.16	1.10	1.15	1.12	1.17	1.14	0.02	2.72
Este	Letonia*	1.08	1.10	1.07	1.09	1.13	1.17	1.16	1.12	1.13	0.04	6.18
Este	Lituania*	0.92	1.00	0.98	0.97	1.00	1.04	1.07	1.07	1.01	0.05	14.80
Este	Polonia	1.03	1.06	1.06	1.03	0.97	0.97	0.98	0.98	1.01	0.04	-5.94
Este	Eslovaquia	1.11	1.08	1.09	1.11	1.12	1.17	1.17	1.19	1.14	0.04	5.56
Este	Eslovenia	0.95	0.97	0.91	0.90	0.87	0.89	0.85	0.86	0.90	0.05	-9.86
Este	Ucrania*	1.08	1.24	1.29	1.30	1.37	1.43	1.44	1.44	1.34	0.11	30.02
<b>Media países del este</b>		<b>1.06</b>	<b>1.09</b>	<b>1.08</b>	<b>1.09</b>	<b>1.10</b>	<b>1.12</b>	<b>1.11</b>	<b>1.12</b>	<b>1.10</b>	<b>0.05</b>	<b>4.89</b>
<b>Media países de la antigua URSS</b>		<b>1.03</b>	<b>1.11</b>	<b>1.11</b>	<b>1.13</b>	<b>1.17</b>	<b>1.19</b>	<b>1.19</b>	<b>1.18</b>	<b>1.15</b>	<b>0.08</b>	<b>13.45</b>
<b>Media otros países comunistas</b>		<b>1.08</b>	<b>1.07</b>	<b>1.06</b>	<b>1.06</b>	<b>1.03</b>	<b>1.05</b>	<b>1.03</b>	<b>1.05</b>	<b>1.06</b>	<b>0.04</b>	<b>-3.22</b>

\*países de la antigua URSS.



**Tabla 3.7** Valores del índice de Moran global y p-valores asociados para los hombres

Edad	Año	I.Moran	V.Esperado	Varianza	p-valor (M)	p-valor (MC)
0-14	1990	0.72	-0.04	0.02	0.00 *	0.00 *
0-14	2012	0.37	-0.04	0.02	0.00 *	0.00 *
15-64	1990	0.79	-0.04	0.02	0.00 *	0.00 *
15-64	2012	0.78	-0.04	0.02	0.00 *	0.00 *
65-110+	1990	0.57	-0.04	0.02	0.00 *	0.00 *
65-110+	2012	0.78	-0.04	0.02	0.00 *	0.00 *

\*p-valores <0.05 son significativos

Después de la cuantificación descriptiva del CMF y con el fin de probar la hipótesis de dependencia espacial de la mortalidad, se contrastó la hipótesis nula  $H_0 : GM_{g,t,s} = 0$ . El resultado de esta prueba se contrastó con la prueba de Monte Carlo (MC) (Bivand 2012). Estos contrastes se detallaron en la Sección 1.3.1. El resultado de las pruebas de Moran y Monte Carlo se muestran en las Tablas 3.7-3.8 las cuales incluyen para cada grupo de edad y los años 1990 y 2012 el valor del índice de Moran observado, el valor esperado, la varianza y el p-valor de la prueba de Moran (M) y en la última columna el p-valor de la prueba de Monte-Carlo (MC) para hombres y mujeres respectivamente. Los p-valores obtenidos para todos los años, grupos de edad y ambos sexos son significativos, lo que indica que existe una dependencia espacial en la mortalidad observada entre los países.

Tal y como se indicó en la Sección 3.2.2, el índice de Moran local permite la detección de agrupaciones significativas de países. En las Figuras 3.1-3.2 <sup>1</sup> se observan clusters significativos de diferentes países europeos, identificando en ellos el centro y los vecinos. La Figura 3.1 muestra los clusters significativos en Europa para los hombres, con edades comprendidas entre 65-110+ años para los años 1990 y 2012 y la Figura 3.2 para las mujeres.

Dependiendo del año, sexo y grupo de edad considerados, los países que forman los diferentes clusters y sus centros varían, pero comparando todos los mapas realizados, principalmente se observan dos clusters significativos, en personas con edades superiores a 64 años: un cluster de alto CMF compuesto por los

<sup>1</sup>Los mapas de shapefile utilizados en este trabajo se basan en la siguiente fuente: ©EuroGeographics para los límites administrativos. En concreto, se utilizó el shapefile mapa del mundo de escala 1:20 Millones correspondientes al periodo 2013. [http://ec.europa.eu/eurostat/cache/GISCO/geodatafiles/NUTS\\_2013\\_20M.zip](http://ec.europa.eu/eurostat/cache/GISCO/geodatafiles/NUTS_2013_20M.zip)

**Tabla 3.8** Valores del índice de Moran global y p-valores asociados para las mujeres

Edad	Año	I.Moran	V.Esperado	Varianza	p-valor (M)	p-valor (MC)
0-14	1990	0.65	-0.04	0.02	0.00 *	0.00 *
0-14	2012	0.34	-0.04	0.02	0.00 *	0.00 *
15-64	1990	0.62	-0.04	0.02	0.00 *	0.00 *
15-64	2012	0.69	-0.04	0.02	0.00 *	0.00 *
65-110+	1990	0.63	-0.04	0.02	0.00 *	0.00 *
65-110+	2012	0.70	-0.04	0.02	0.00 *	0.00 *

\*p-valores <0.05 son significativos

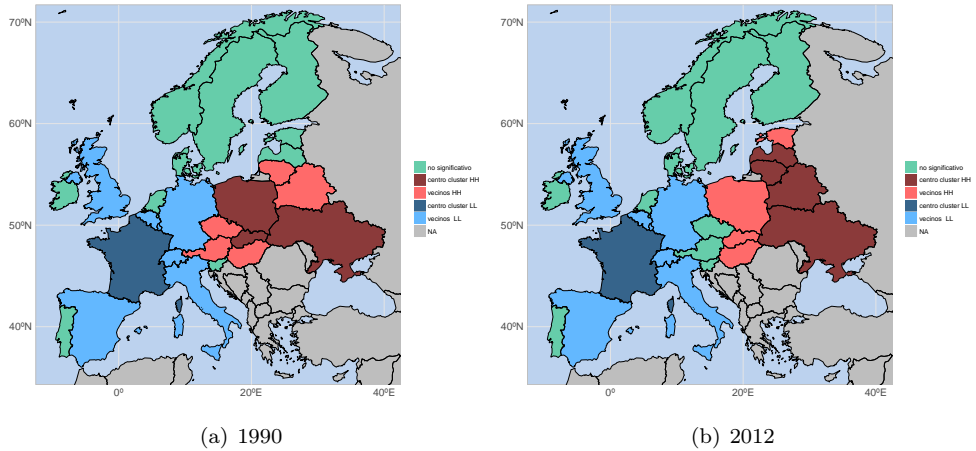
países del este de Europa (Polonia, Lituania, Letonia, Estonia, Ucrania, Bielorrusia, Eslovaquia y Hungría) y otro grupo formado por países del oeste de Europa (Reino Unido, Austria, España, Italia, Francia, Suiza, Alemania, Luxemburgo y Bélgica), tal y como indica el valor significativo del índice de Moran local. Por contra, valores no significativos de este índice identifican países que no pertenecen a ningún cluster. Estos países son (República Checa, Portugal, Dinamarca, Finlandia, Irlanda, Países Bajos, Noruega, Eslovenia y Suecia).

En este caso, es necesario enfatizar dos eventos:

- Austria pertenece al cluster formado por países del este de Europa en las siguientes ocasiones:
  - $g_1$  en los años 2009, 2010 y 2012 para las mujeres y en los años 2010 y 2012 para los hombres.
  - $g_2$  en el año 1990 para los hombres.
  - $g_3$  en los años 1990 y 1991 para los hombres y en los años 2005, 2006, 2008, 2009, 2010, 2011 y 2012 para las mujeres

Esto es debido a que Austria comparte frontera con Eslovaquia y Hungría, países que ocasionalmente pertenecen al centro del cluster.

- En el cluster HH (alto CMF) se observan varios centros clusters. Esto es debido a que existen varios clusters de tipo HH que forman un macrocluster único HH. Estos centros varían en el período estudiado, moviéndose del oeste al este de Europa.

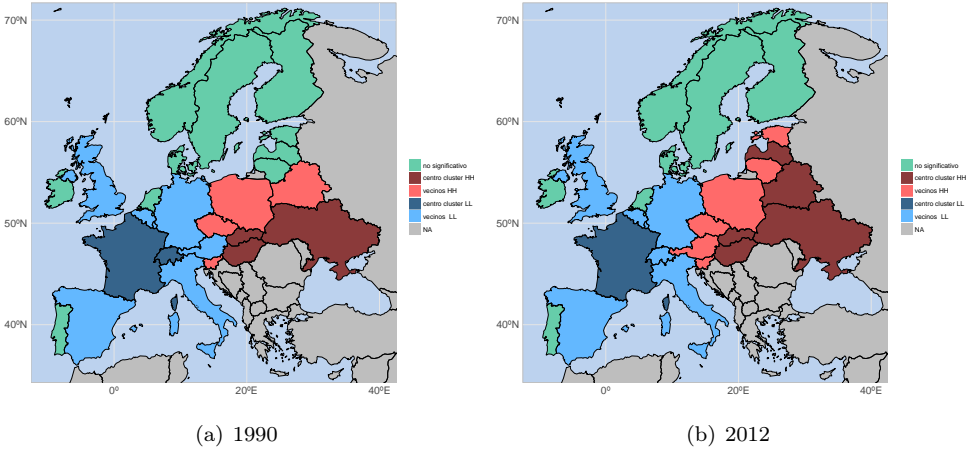


**Figura 3.1.** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años para los años 1990 y 2012 en Europa.

- En el cluster LL (bajo CMF) se observan uno o dos centros clusters, dependiendo del grupo de edad, sexo y año considerado. En ocasiones el centro es único (Francia) y en ocasiones se observan dos centros (Francia y Suiza) formando un único macrocluster LL.

Por el contrario, para las edades inferiores o iguales a 64, sólo se observa un cluster significativo de tipo HH formado por países del este de Europa (Polonia, Lituania, Letonia, Estonia, Ucrania, Bielorrusia, Eslovaquia y Hungría), mientras que para el resto de países, el índice de Moran local no es significativo.

A continuación se estudió la interacción espacio-tiempo tal y como se describió en la Sección 3.2.2. Para este propósito, las estimaciones de las matrices de las probabilidades de transición se calcularon para cada grupo de edad y sexo durante el período 1990-2012. Estas probabilidades se estimaron suponiendo homogeneidad temporal a lo largo de las frecuencias observadas correspondientes. La Tabla 3.9 muestra los valores de la prueba  $\chi^2$  para ambos sexos y cada grupo de edad durante el período 1990-2012. Valores muy altos de la prueba  $\chi^2$  significan que los p-valores asociados con la prueba son muy significativos y concluyen que la interacción espacio-tiempo es significativa, es decir, el CMF de un país y en su entorno evolucionan dinámicamente durante el período 1990-2012 para todos los grupos de edad y ambos sexos. En particular, la interacción espacio-tiempo para los hombres en la edad adulta es la más significativa. Los resultados de la Tabla 3.9 confirman nuestros hallazgos en las Figuras 3.1-3.2



**Figura 3.2.** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años para los años 1990 y 2012 en Europa.

donde los clusters varían con el tiempo dependiendo del grupo de edad y el sexo considerado.

### 3.4 Conclusiones

Aunque las diferencias de mortalidad entre los países orientales y occidentales está creciendo de acuerdo a nuestros resultados, no atrae la atención que realmente se merece (Leon 2011; Vågerö 2010). En particular, los hombres sufren más mortalidad que las mujeres, especialmente los hombres en edades adul-

**Tabla 3.9** Valores de la prueba  $\chi^2$

Sexo	Grupo de edad	$\chi^2$	p-valor
Masculino	0-14	61.63	0.00 *
	15-64	158.02	0.00 *
	65-110+	29.78	0.00 *
Femenino	0-14	82.39	0.00 *
	15-64	85.49	0.00 *
	65-110+	80.75	0.00 *

\*p-valores <0.05 son significativos

tas. Las diferencias entre los países del este y del oeste de Europa son grandes debido a enfermedades como la cardiopatía isquémica, derrames cerebrales, otras enfermedades del corazón, cánceres relacionados con el tabaco, lesiones y muertes relacionadas con el alcohol (Bonneux, Huisman y de Beer 2010).

Las principales conclusiones sobre los resultados de cuantificar la dinámica de la mortalidad en Europa a través del CMF permiten concluir:

La brecha entre Europa del este y del oeste se está ampliando porque, teniendo en cuenta la media y la desviación estándar, el CMF de los países del este es más alto que los países del oeste de Europa. Esta brecha es mayor para los hombres en las edades infantiles y edades adultas que para las mujeres.

Centrándonos en los países de la antigua URSS, éstos tienen una media y una desviación estándar del CMF mayor que el resto de los países del este para los hombres en las edades infantiles y adultas. Hay que destacar el alto CMF promedio en los países de la antigua URSS para los hombres en la edad adulta, en comparación con el resto de Europa. Nuestros resultados para un período más reciente son consistentes con los obtenidos en trabajos como Meslé y Vallin (2002) y Bonneux, Huisman y de Beer (2010). En ellos, se muestra que los países del este de Europa y, especialmente los países de la antigua URSS, los hombres sufren exceso de mortalidad en edades adultas. En concreto, entre 1990 y 1994 se detectó un aumento en la media del CMF en países de la antigua URSS. Este hecho se asocia con el colapso de la Unión Soviética, el cual hizo que entre 1990 y 1994 la esperanza de vida en estos países disminuyera (Leon 2011).

Portugal sufrió la mayor disminución de CMF en edades infantiles durante el período 1990-2012. Estas mejoras se explican por las reducciones masivas de la tasa de mortalidad infantil (TMI), ya que en 1970 Portugal tenía la TMI más alta (50 por 1000 nacidos vivos) de Europa (Leon 2011). Por lo que respecta a Luxemburgo, también sufrió una disminución del CMF en edades infantiles durante 1990-2012. Esta disminución está de acuerdo con el trabajo United Nations Interagency Group for Child Mortality Estimation (2013), el cual indica que Luxemburgo alcanzó en 2012 una tasa de mortalidad de niños menores de cinco años de 2 muertes por cada 1.000 nacidos vivos con una tasa de reducción promedio anual de 6.2 % en 1990-2012.

Eslovenia es el país del este de Europa con el CMF por debajo de la media para todos los grupos de edad, todos los años y ambos sexos. Trnka y col. (1998) señalan que entre 1994-1996 la vacunación primaria en masa y la revacunación general fueron extremadamente frecuentes en los países del este donde la

prevalencia de la tuberculosis era alta. Eslovenia fue el único país del este de Europa que se adhirió a las directrices de la Organización Mundial de la Salud (OMS), en las que no se aplicaron la revacunación y la prueba cutánea de la tuberculosis. De forma similar, Ucrania tiene un CMF por encima de la media de todos los países del este para todos los años considerados, en ambos sexos y todos los grupos de edad. Esto se confirma en el trabajo de Meslé (2004), el cual indicó que aunque las tendencias recientes de la situación sanitaria en los países del oeste de Europa son bastante favorables, el futuro de los países de la antigua URSS como Rusia y Ucrania es no favorable. Estos países no muestran signos de mejora y la mortalidad ha seguido aumentando.

Además de cuantificar la dinámica de la mortalidad en Europa este trabajo detecta diferencias significativas en la mortalidad entre países utilizando medidas y técnicas tales como: el índice de Moran global, índice de Moran local y Markov espacial. En concreto, el CMF proporciona un estadístico adecuado para la comparación de la mortalidad de cada país por sexo. Los dos índices de autocorrelación espacial se usan ampliamente en econometría, epidemiología y demografía. Ambos, son índices estáticos en el sentido de que miden la autocorrelación espacial en un momento determinado del tiempo (Rey 2001; Rey 2014). La última medida, se utiliza para probar la hipótesis de significación de la interacción entre tiempo y espacio en el análisis de la mortalidad en diferentes países.

A continuación se detallan las conclusiones más importantes de detectar diferencias significativas en la mortalidad aplicando la metodología espacio-temporal entre países.

Se ha confirmado una correlación espacial en la mortalidad de los 26 países europeos estudiados, tal y como lo indican los valores del índice de Moran global y local.

Se observaron diferentes clusters significativos según el año, sexo y grupo de edad considerados, pero principalmente para edades superiores a 64, se obtuvieron dos clusters significativos: un cluster de países con altos valores de CMF rodeados de vecinos con altos valores de CMF formado por países del este de Europa (Polonia, Lituania, Letonia, Estonia, Ucrania, Bielorrusia, Eslovaquia y Hungría) y otro cluster de países con valores bajos de CMF rodeados de vecinos con bajos valores de CMF compuesto por países del oeste de Europa (Reino Unido, Austria, España, Italia, Francia, Suiza, Alemania, Luxemburgo y Bélgica). Los valores no significativos del índice de Moran local identifican países que no pertenecen a ningún cluster (República Checa, Portugal, Dinamarca, Finlandia, Irlanda, Países Bajos, Noruega, Eslovenia y Suecia).

Para las edades inferiores o iguales a 64 sólo aparece un cluster significativo de países con altos valores de CMF rodeados de vecinos con altos valores de CMF formado por países de Europa del este (Polonia, Lituania, Letonia, Estonia, Ucrania, Bielorrusia, Eslovaquia y Hungría), mientras que los valores del índice de Moran local para el resto de países no son significativos, y por tanto, no pertenecen a ningún grupo.

Por último, el método Markov espacial confirma la existencia de una interacción espacio-tiempo, lo que significa que existe una dependencia espacio-temporal dinámica entre los 26 países europeos estudiados durante el período 1990-2012. Por esta razón, los clusters obtenidos y sus centros varían con el tiempo dependiendo del grupo de edad y sexo considerado. En particular, la interacción espacio-tiempo para los hombres adultos es la más significativa.

Existen estudios que abordan las diferencias en la esperanza de vida al nacer en Europa. Por ejemplo Meslé y Vallin (2002) que mostraron un cluster jerárquico de los patrones de mortalidad por edad por sexo en los años 1965 y 1995. Leon (2011) estudió las tendencias en la esperanza de vida al nacer en Europa y Japón por sexo, utilizando un gráfico que muestra la evolución temporal de esta variable durante 1970-2008. Shaw y col. (2000) que analizaron patrones geográficos de mortalidad de 160 regiones de 15 países europeos en los años 1990 y 1994. En este último trabajo, la mortalidad se cuantificó utilizando el SMR y se presentó para diferentes causas de muerte mediante mapas, sin distinguir entre hombres y mujeres. Todos estos autores estudian las diferencias en la mortalidad en Europa, pero ninguno de ellos cuantifica las diferencias en la mortalidad por edad y sexo, comprobando a su vez que son significativas. Por lo tanto, nuestro estudio espacio-temporal es complementario a otras técnicas. Además, la metodología estadística empleada en este trabajo, considera las relaciones de vecindad entre países, el elemento del tiempo y su interacción.





# Conclusiones y futuras líneas de investigación

En la introducción de esta tesis se mostraba la necesidad de extender los estudios actuales de mortalidad europea con estudios espaciales, los cuales tienen en cuenta la ubicación geográfica de los países, el tiempo y su interacción. Por ello, se fijaba como objetivo del presente trabajo cuantificar la mortalidad en Europa para poder realizar comparaciones entre países y disponer de modelos, métodos y softwares que permitan estudiar la mortalidad en Europa teniendo en cuenta la ubicación geográfica y el tiempo.

A continuación, se muestran las principales conclusiones de cada capítulo de esta tesis que demuestran que se han cumplido los objetivos marcados.

### Capítulo 1

- La aplicación de la metodología espacio-temporal, confirmó la dependencia espacial de la mortalidad de los países a lo largo del tiempo formando dos clusters significativos en Europa, uno formado por países del este y otro por países del oeste.

- Acorde con la tipología de los datos, se implementó un modelo de retardo espacial con efecto fijo espacial y temporal, el cual modelizó de forma correcta la dependencia espacio-tiempo.
- La mayoría de los países que forman los diferentes clusters y su exceso o defecto de mortalidad respecto de Europa se confirmaron en los efectos fijos del modelo.

## Capítulo 2

- Se detalla e implementa en el software libre R una metodología espacio-temporal para seleccionar el mejor modelo espacial de datos de panel.
- El mejor modelo espacial de datos de panel que se obtuvo con en el software R fue el modelo de retardo espacial con efecto fijo espacial y temporal. Por tanto, se confirma el modelo implementado en el Capítulo 1.
- El mejor modelo que se consiguió con el software Matlab fue el modelo Durbin espacial, el cual, a diferencia del modelo obtenido en R, incluye además la dependencia espacial en las covariables.

## Capítulo 3

- La aplicación de la metodología espacio-temporal, confirmó la dependencia espacial de la mortalidad de los países medida por el CMF por sexo y grupos de edad formando dos clusters significativos en Europa para el grupo con edades superiores a 64 años: uno formado por países del este y otro por países del oeste.
- Por contra, para los dos grupos de edades inferiores o iguales a 64 sólo se detectó un cluster significativo formado por países del este de Europa. Lo que significa que los países del oeste en estas edades no evolucionan conjuntamente.
- Finalmente se confirmó la interacción espacio-tiempo de los datos, por esa razón, los clusters obtenidos varían con el tiempo dependiendo del grupo de edad y sexo considerado.

En cuanto al trabajo futuro, dentro de la misma línea de investigación de la presente tesis, se muestran principalmente dos:

- Aplicar el modelo de retardo espacial con efecto fijo espacial y temporal implementado en los Capítulos 1-2 con el objetivo de modelizar el CMF

---

para el grupo de edad de 65 y más años para los 49 estados del continente americano. El objetivo de este proyecto es explicar el patrón de mortalidad en personas adultas, por sexo y por estado para el período 1970-2013, dependiendo de variables demográficas y económicas como el índice de Gini, daños de desastres naturales o el producto interior bruto.

- Estudiar el patrón espacial de la esperanza de vida al nacer para ambos sexos en los distritos metropolitanos franceses a lo largo de los siglos XIX y XX. Para ello, en primer lugar se aplicó la metodología espacio-temporal detallada en el Capítulo 1 para detectar clusters significativos de departamentos franceses con patrones de evolución similares o diferentes durante el período mencionado. En segundo lugar, estudiar el efecto de las covariables índice de fertilidad, índice de fecundidad marital e índice de nupcialidad en los cambios de la esperanza de vida mediante un modelo espacial. En este trabajo, la dimensión temporal de la esperanza de vida se reduce a un sólo valor el cual mide la distancia o afinidad entre las funciones del tiempo en cada departamento.



# Bibliografía

- Anderson, T.W. y L.A. Goodman (1957). “Statistical inference about Markov chains”. En: *The Annals of Mathematical Statistics* 28.1, págs. 89-110.
- Anselin, L. (1988). *Spatial econometrics: Methods and models*. Boston. Kluwer Academic.
- (1995). “Local Indicators of Spatial Association—LISA”. En: *Geographical Analysis* 27.2, págs. 93-115.
- Anselin, L., S. Sridharan y S. Gholston (2007). “Using exploratory spatial data analysis to leverage social indicator databases: the Discovery of interesting patterns”. En: *Social Indicators Research* 82, págs. 287-309.
- Arbia, G. y G. Piras (2005). “Convergence in per-capita GDP across European regions using panel data models extended to spatial autocorrelation effects”. En: *Instituto di Studi e Analisi Economica*. Working Paper 51.
- Asteriou, D. y S.G. Hall (2015). *Applied econometrics (3rd edition)*. New York. Palgrave Macmillan.
- Baltagi, B. (2008). *Econometric analysis of panel data*. John Wiley & Sons.
- Baltagi, B.H, G. Bresson y A. Pirotte (2003). “Fixed effects, random effects or Hausman–Taylor? A pretest estimator”. En: *Economics letters* 79, págs. 361-369.

- Bivand, R. (2012). *spdep: Spatial Dependence: Weighting Schemes, Statistics and Models*. R package version 0.5-53.
- Bivand, R. y N. Lewin-Koh (2016). *maptools: Tools for reading and handling spatial objects*. <https://CRAN.R-project.org/package=maptools>. R package version 0.8-39.
- Bivand, Roger, Tim Keitt y Barry Rowlingson (2015). *rgdal: Bindings for the Geospatial Data Abstraction Library*.
- Bobadilla, J.L., C.A. Costello, F. Mitchell y col. (1997). “Premature death in the new independent states: overview”. En: National Academies Press. Cap. Premature Death in the New Independent States, págs. 1-33.
- Bonneux, L.G., C.C. Huisman y J.A. de Beer (2010). “Mortality in 272 European regions, 2002-2004. An update”. En: *European Journal of Epidemiology* 25.2, págs. 77-85.
- Breslow, N.E. y N.E. Day (1987). “The design and analysis of cohort studies”. En: *International Agency for Research on Cancer* 2.82. Lyon, págs. 65-73.
- Breusch, T.S. y A.R. Pagan (1980). “The Lagrange multiplier test and its applications to model specification in econometrics”. En: *Review of Economic Studies* 97, págs. 239-253.
- Burridge, P. (1980). “On the Cliff-Ord test for spatial autocorrelation among regression residuals”. En: *Geographical Analysis* 4, págs. 267-284.
- Charpentier, A. (2014). “Computational Actuarial Science with R”. En: Chapman y Hall/CRC. Cap. Spatial Analysis.
- Cliff, A.D. y J.K. Ord (1973). *Spatial autocorrelation*. Monographs in spatial and environmental systems analysis. Pion.
- Croissant, Y. y G. Millo (2008). “Panel data econometrics in R: The plm package”. En: *Journal of Statistical Software* 27.2, págs. 1-43.
- Cutler, D., A. Deaton y A. Lleras-Muney (2006). “The determinants of mortality”. En: *Journal of Economic Perspectives* 20.3, págs. 97-120.

- 
- Diehl, P. (1992). "Geography and war: A review and assessment of the empirical literature". En: *The New Geopolitics*, edited by M. Ward. Philadelphia, PA: Gordon and Breach, págs. 37-121.
- Elhorst, J.P. (2003). "Specification and estimation of spatial panel data models". En: *International regional science review* 26.3, págs. 244-268.
- (2010). "Applied spatial econometrics: raising the bar". En: *Spatial Economic Analysis* 5.1, págs. 9-28.
- (2011). *Matlab software to estimate spatial panels*. Version 2011-04-11, <http://www.regroningen.nl/elhorst/software.shtml> (routines downloaded on 6th May 2015).
- (2012). "Dynamic spatial panels: models, methods, and inferences". En: *Journal of geographical systems* 14.1, págs. 5-28.
- (2014). *Spatial econometrics: from cross-sectional data to spatial panels*. Springer.
- EUROSTAT (2009). "Health statistics - atlas on mortality in the European Union". En: *European Communities*. Luxembourg.
- (2013). "Quality of life indicators - measuring quality of life". En: *European Communities*. Luxembourg.
- Fischer, M.M. y col. (2009). "The impact of human capital on regional labor productivity in Europe". En: *Letters in Spatial and Resource Sciences* 2, págs. 97-108.
- Fleiss, J.L., B. Levin y M.C. Paik (2013). *Statistical methods for rates and proportions*. Wiley Series in Probability and Statistics. Wiley.
- General Register Office (1884). *Annual report of the Registrar General for England and Wales*. London. HM Stationery Office.
- Gersmehl, P. (2014). *Teaching geography (3rd edition)*. Guilford Publications.

- Golgher, A.B. y P.R. Voss (2016). “How to interpret the coefficients of spatial models: Spillovers, direct and indirect effects”. En: *Spatial Demography* 4.3, págs. 175-205.
- Goovaerts, P. y G.M. Jacquez (2005). “Detection of temporal changes in the spatial distribution of cancer rates using local Moran’s I and geostatistically simulated spatial neutral models”. En: *Journal of Geographical Systems* 7.1, págs. 137-159.
- Gordon, M. (2016). *Gmisc: descriptive statistics, transition plots, and more*. R package version 1.3.1. <https://CRAN.R-project.org/package=Gmisc>.
- Hinde, A. (1998). *Demographic methods*. Oxford, UK. Oxford University Press.
- Hsiao, C. (2014). “Analysis of Panel Data (3rd edition)”. En: Cambridge: Cambridge University Press. Cap. Simple regression with variable intercepts.
- Human Mortality Database (2014). *University of California, Berkeley (USA), and Max Planck Institute for Demographic Research (Germany)*. Available at [www.mortality.org](http://www.mortality.org) or [www.humanmortality.de](http://www.humanmortality.de) (data downloaded on 17th April 2014).
- (2016). *University of California, Berkeley (USA), and Max Planck Institute for Demographic Research (Germany)*. Available at [www.mortality.org](http://www.mortality.org) or [www.humanmortality.de](http://www.humanmortality.de) (data downloaded on 12th July 2016).
- Hyndman, R.J. y col. (2014). *demography: Forecasting mortality, fertility, migration and population data*. R package version 1.18. <https://CRAN.R-project.org/package=demography>.
- Julious, S.A., J. Nicholl y S. George (2001). “Why do we continue to use standardized mortality ratios for small area comparisons?” En: *Journal of Public Health* 23.1, págs. 40-46.
- Kapoor, M., H.H. Kelejian e I.R. Prucha (2007). “Panel data models with spatially correlated error components”. En: *Journal of econometrics* 140, págs. 97-130.
- Kennedy, P. (2003). *A guide to econometrics*. Cambridge, MA. MIT press.



- 
- Laurent, T., A. Ruiz-Gazen y C. Thomas-Agnan (2012). “GeoXp: an R Package for exploratory spatial data analysis”. En: *Journal of Statistical Software* 47.2. <http://www.jstatsoft.org/v47/i02/>, págs. 1-23.
- Leon, D.A. (2011). “Trends in European life expectancy: a salutary view”. En: *International Journal of Epidemiology* 40, págs. 271-277.
- LeSage, J.P y R.K. Pace (2009). *Introduction to Spatial Econometrics*. Boca Raton, FL: CRC Press Taylor & Francis Group.
- Li, H. y col. (2012). En: *Journal of Economic Perspectives* 26.4, págs. 57-74.
- Mackenbach, J.P., M. Karanikolos y M. McKee (2013). “The unequal health of Europeans: successes and failures of policies”. En: *Lancet* 381, págs. 1125-1134.
- MathWorks, The (2015). *MATLAB - The Language of Technical Computing, Version 8.5.0.197613*. <http://www.mathworks.com/products/matlab/>. Natick, Massachusetts.
- Meslé, F. (2004). “Mortality in Central and Eastern Europe: Long-term trends and recent upturns”. En: *Demographic Research* 2, págs. 45-70.
- Meslé, F. y J. Vallin (2002). “Mortality in Europe: The divergence between East and West”. En: *Population (English Edition)* 57.1, págs. 157-197.
- Millo, G. y G. Piras (2012). “splm: Spatial panel data models in R”. En: *Journal of Statistical Software* 47.1. <http://www.jstatsoft.org/v47/i01/>, págs. 1-38.
- Moran, P. A. P. (1950a). “Notes on continuous stochastic phenomena”. En: *Biometrika* 37, págs. 17-23.
- (1950b). “A Test for the serial independence of residuals”. En: *Biometrika* 37, págs. 178-181.
- Neuwirth, E. (2014). *RColorBrewer: ColorBrewer alettes*. R package version 1.1-2. <https://CRAN.R-project.org/package=RColorBrewer>.

- Quah, D. (1993). “Galton’s fallacy and tests of the convergence hypothesis”. En: *The Scandinavian Journal of Economics* 95.4, págs. 427-443.
- R Core Team (2015). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria.
- Rey, S.J. (2001). “Spatial empirics for economic growth and convergence”. En: *Geographical Analysis* 33.3, págs. 195-214.
- (2014). “Spatial dynamics and space-time data analysis”. En: *Handbook of Regional Science*. Springer Berlin Heidelberg, págs. 1365-1383.
- Rezaeian, M. y col. (2007). “Geographical epidemiology, spatial analysis and geographical information systems: a multidisciplinary glossary”. En: *Journal of Epidemiology and community Health* 61, págs. 98-102.
- Riffe, T. (2015). *Reading Human Fertility Database and Human Mortality Database data into R*. Inf. téc. TR-2015-004. MPIDR.
- Shaw, M. y col. (2000). “Widening inequality in mortality between 160 regions of 15 European countries in the early 1990s”. En: *Social Science & Medicine* 50.7-8, págs. 1047 -1058.
- Shiba, T. y H. Tsurumi (1988). “Bayesian and non-Bayesian tests of independence in seemingly unrelated regressions”. En: *International Economic Review* 29, págs. 377-395.
- Spinakis, A. y col. (2011). *Expert Review and proposals for measurement of health inequalities in the European Union-Full Report*. Luxembourg. European Commission Directorate General for Health y Consumers.
- The World Bank Database (2015). *World Development Indicators*. Data download on 9th January 2015 en <http://data.worldbank.org/>.
- Torgo, L. (2010). *Data Mining with R, learning with case studies*. Chapman y Hall/CRC.
- Trnka, L. y col. (1998). “Survey of BCG vaccination policy in Europe: 1994-96”. En: *Bulletin of the World Health Organization* 76, págs. 85-91.

- United Nations Interagency Group for Child Mortality Estimation (2013). *Levels & Trends in Child Mortality: Report 2013*. Inf. téc. UNICEF.
- Vågerö, D. (2010). “The east - west health divide in Europe: growing and shifting eastwards”. En: *European Review* 18.01, págs. 23-34.
- Vaupel, J.W., Z. Zhang y A.A. van Raalte (2011). “Life expectancy and disparity: an international comparison of life table data”. En: *BMJ open* 1.1.
- Vega, S.H. y J.P. Elhorst (2012). “On spatial econometric models, spillover effects, and W”. En: *ERSA Conference 2013*. Palermo Italy, August 27-31.
- Ward, M.D. y K.S. Gleditsch (2008). *Spatial Regression Models*. SAGE Publications, Thousand Oaks, CA.
- Wickham, H. y W. Chang (2016). *devtools: Tools to make developing R packages easier*. <https://CRAN.R-project.org/package=devtools>. R package version 1.11.1.
- Wooldridge, J.M. (2010). *Econometric analysis of cross section and panel data*. MIT press.
- Zwerling, A. y col. (2011). “The BCG World Atlas: a database of Global BCG vaccination policies and practices”. En: *PLoS Med.*



# Apéndice A

## Código R

```
1 #####
2 Estimación de un modelo no espacial versus modelos con datos de
3 panel no espaciales (TablaXX)
4 #####
5
6 library(plm)
7
8 f <- (logSMR ~ Tasa natalidad + tasa actividad + cons energía +
9       PIB )
10 OLS<- plm(f, data=datos, index=c("país", "año"), model = "pooling
11       ")
12 summary(OLS)
13 MSFE<- plm(f, data=datos, index=c("país", "año"), effect = "
14       individual", model = "within")
15 summary(MSFE)
16 fixef(MSFE, effect = "individual")
17 MTFE<- plm(f, data=datos, index=c("país", "año"), effect = "time"
18       ,model = "within")
19 summary(MTFE)
20 fixef(MTFE, effect = "time")
```

```

20
21 MSTFE<- plm(f, data=datos, index=c("país", "año"), effect = "
      twoways",model = "within")
22 summary(MSTFE)
23 fixef(MSTFE, effect = "individual")
24 fixef(MSTFE, effect = "time")
25
26 #####
27 Estimación de la prueba clásica del LM en los modelos anteriores
      (TablaXX)
28 #####
29
30 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año")
      , test="lml", model = "pooling")
31 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año"
      ),test="lme", model = "pooling")
32
33 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año"
      ),test="lml", effect = "individual",model = "within")
34 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año"
      ),test="lme", effect = "individual",model = "within")
35
36 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año"
      ),test="lml", effect = "time", model = "within")
37 slmtest(f, data=datos, listw = matrizpesos, index=c("país", "año"
      ),test="lme", effect = "time", model = "within")
38
39 slmtest(f, data=datos, listw = matrizpesos, index=c("país''", "año"
      ),test="lml", effect = "twoways",model = "within")\\
40 slmtest(f, data=datos, listw = matrizpesos, index=c("país''", "año"
      ),test="lme", effect = "twoways",model = "within")\\
41
42 #####
43 Resultado de la prueba LM para el efecto espacial, temporal y
      ambos en R (TablaXX)
44 #####
45
46 #En la fórmula del modelo, se elimina la variable no
      significativa tasa natalidad.
47
48 fm <- (logSMR ~ tasa actividad + cons energía + PIB)
49
50 OLS<- plm(fm, data=datos, index=c("país", "año"), model = "
      pooling")
51 plmtest(OLS, effect =c("twoways"), type=("bp"))
52 plmtest(OLS, effect =c("individual"), type=("bp"))

```

```

53 plmtest(OLS, effect =c("time"), type=("bp"))
54
55 #####
56 Resultado del test de Hausman en R (TablaXX)
57 #####
58
59 #Debemos de destacar que el efecto "twoways" en el modelo de
    efectos aleatorios no está implementado, por esa razón
    tampoco lo indicamos en el modelo de efectos fijos. Al no
    indicar el efecto, en ambos modelos R toma como efecto sólo
    el espacial.
60
61 library(splm)
62
63 SLMFE<- splm(fm,data=datos, index=c("país","año"), listw =
    matrizpesos,lag=TRUE, model = "within", spatial.error="none")
64
65
66 SLMRE<- splm(fm,data=datos, index=c("país","año"), listw =
    matrizpesos,lag=TRUE, model = "random", spatial.error="none")
67 sphtest(SLMFE, SLMRE)
68
69 #####
70 Resultado del SLMSTFE en R (TablaXX)
71 #####
72
73 SLMSTFE<- splm(fm,data=datos, index=c("país","año"), listw =
    matrizpesos, lag=TRUE, model = "within", spatial.error="none"
    , effect="twoways")
74
75 summary(SLMSTFE)
76
77 ##Obtención del coeficiente de determinación
78
79 #varianza residual 0.00144135
80 modelo$sigma2
81
82 #varianza total 0.05699808
83 var(datos$logSMR)
84
85 #R2 0.9749543
86 1-(0.00144135/0.05699808)
87
88
89 #####

```

```

90  Estimación de los efectos espaciales y temporales del SLMSTFE en
      R (TablaXX)
91  #####
92
93  effects(SLMSTFE)
94
95  #####
96  Estimaciones de efectos directos e indirectos basados en los
      coeficientes del SLMSTFE (TablaXX)
97  #####
98
99
100  impactos <- impacts(SLMSTFE, listw = mat2listw(matrizpesos, style
      = "W"), time = 17)
101  summary(impactos, zstats=TRUE, short=T)
102
103
104  # A continuación se muestra la función impacts de Giovanni Millo
      version 1.3-7.
105
106  impacts.splm<-function(obj, listw = NULL, time = NULL, ..., tr=
      NULL, R=200, type="mult", empirical=FALSE, Q=NULL){
107
108  if(is.null(listw) && is.null(tr)) stop("either listw or tr should
      be provided")
109
110
111  if(!is.null(listw) ){
112      if(listw$style != "W") stop("Only row-standardised
          weights supported")
113      if(is.null(time) && is.null(tr)) stop("time periods
          should be provided")
114  }
115
116
117  if(is.null(tr)){
118
119  sparse.W <- listw2dgCMatrix(listw)
120  s.lws <- kronecker(Diagonal(time) , sparse.W)
121  tr <- trW(s.lws, type= type)
122
123      }
124
125  if(is.na(match(obj$type, c("fixed effects lag","fixed effects
      sarar","random effects ML", "fixed effects GM","lag GM","
      fixed effects GM")))) stop("object type not recognized")

```



```

126         if(obj$type == "fixed effects lag"){
127
128
129         class(obj)<- "gmsar"
130         obj$type <- "SARAR"
131         obj$data <- as.vector(obj$model)
132         obj$s2 <- obj$sigma2
133         obj$secstep_var <- obj$vcov
134         imp <- impacts(obj, tr=tr, R=R, ...)
135
136         }
137
138         if(obj$type == "fixed effects sarar"){
139
140         class(obj)<- "gmsar"
141         obj$type <- "SARAR"
142         rho <- obj$coefficients[2]
143         obj$coefficients <- obj$coefficients[-2]
144         obj$data <- as.vector(obj$model)
145         obj$s2 <- obj$sigma2
146         obj$secstep_var <- obj$vcov[-2,-2]
147         imp <- impacts(obj, tr=tr, R=R,...)
148
149         }
150
151         if(obj$type == "fixed effects error") stop("Impacts
152             Estimates are not available for Error Model")
153
154         if(obj$type == "random effects ML")      {
155
156         if(!is.null(obj$arcoef)) {
157         class(obj)<- "gmsar"
158         obj$type <- "SARAR"
159
160         obj$coefficients <- c(obj$arcoef, obj$coefficients)
161         obj$data <- as.vector(obj$model)
162         obj$s2 <- obj$sigma2
163         obj$secstep_var <- matrix(0,nrow(obj$vcov)+1,nrow(obj$vcov)+1)
164         obj$secstep_var[1,1] <- obj$vcov$arcoef
165         obj$secstep_var[(2:(nrow(obj$vcov)+1)),(2:(nrow(obj$vcov)+1))] <-
166             obj$vcov
167         imp <- impacts(obj, tr=tr, R=R, ...)
168         }
169         else stop("Impacts Estimates are not available
170             for Error Model")

```

```

169     }
170
171
172     if(obj$type == "fixed effects GM"){
173
174         if(is.null(obj$endog)) {
175 obj$secstep_var <- vcov(obj)
176 class(obj)<- "gmsar"
177 obj$type <- "SARAR"
178 obj$data <- as.vector(obj$model)
179 obj$s2 <- obj$sigma2
180
181 imp <- impacts(obj, tr=tr, R=R, ...)
182
183
184         }
185
186         else stop("No impacts estimates when endogenous
187                 variables are present in the system")
188     }
189
190 if(obj$type == "lag GM") {
191
192     if(is.null(obj$endog)) {
193
194 class(obj)<- "gmsar"
195 obj$type <- "SARAR"
196 obj$secstep_var <- obj$var
197 obj$data <- as.vector(obj$model)
198 obj$s2 <- obj$sigma2
199
200 imp <- impacts(obj, tr=tr, R=R, ...)
201
202
203     }
204
205     else stop("No impacts estimates when endogenous
206             variables are present in the system")
207
208
209 }
210
211
212 if(obj$type == "random effects GM") {

```

---

```
213         if(is.null(obj$endog)) {
214
215
216     class(obj)<- "gmsar"
217     obj$type <- "SARAR"
218     obj$secstep_var <- obj$vcov
219     obj$data <- as.vector(obj$model)
220     obj$s2 <- obj$sigma2
221
222     imp <- impacts(obj, tr=tr, R=R, ...)
223
224
225         }
226
227         else stop("No impacts estimates when endogenous
228                 variables are present in the system")
229
230
231     }
232
233
234
235
236
237     return(imp)
238
239 }
```



# Apéndice B

## Código Matlab

```
1 % Spatial weights matrix constructed by Elhorst
2 %
3 %
4 % written by: J.Paul Elhorst summer 2010
5 % University of Groningen
6 % Department of Economics
7 % 9700AV Groningen
8 % the Netherlands
9 % j.p.elhorst@rug.nl
10 %
11 % REFERENCES:
12 % Elhorst JP (2010) Matlab Software for Spatial Panels. Under
13 % review.
14 % Elhorst JP (2010) Spatial Panel Data Models. In Fischer MM,
15 % Getis A (Eds.)
16 % Handbook of Applied Spatial Analysis, Ch. C.2. Springer: Berlin
17 % Heidelberg New York.
18 %
19 % dimensions of the problem
20 addpath(pwd);
21 A=xlsread('datos.xlsx');
```

```

22 W1=xlsread('matriz_conect.xlsx');
23 T=20; %number of time periods
24 N=26; %number of regions
25 %row-normalize W
26 W=normw(W1); %function of LeSage
27 y=A(:,[5]); %column number in the data matrix that corresponds to
    the dependent variable
28 x=A(:,[7,8,9,10]); %column numbers in the data matrix that
    correspond to the independent variables
29 xconstant=ones(N*T,1);
30 [nobs K]=size(x);
31
32 %-----
33
34 %ols estimation
35 results=ols(y,[xconstant x]);
36 vnames=strvcat('logSMR','intercepto','tasa_nat','ratio_act','
    energia_vial','PIB');
37 prt_reg(results,vnames,1);
38 sig=results.sig*((nobs-K)/nobs);
39 loglikols=-nobs/2*log(2*pi*sig)-1/(2*sig)*results.resid'*results
    .resid
40
41 %The (robust)LM tests developed by Elhorst
42
43 LMsarsem_panel(results,W,y,[xconstant x]); %(Robust) LM tests
44
45 %The lm tests developed by Donald Lacombe
46 %see http://www.rrri.wvu.edu/lacombe/~lacombe.htm
47
48 lm1=lmlag_panel(y,[xconstant x],W);
49 prt_tests(lm1);
50
51 lm2=lmerror_panel(y,[xconstant x],W);
52 prt_tests(lm2);
53
54 lm3=lmlag_robust_panel(y,[xconstant x],W);
55 prt_tests(lm3);
56
57 lm4=lmerror_robust_panel(y,[xconstant x],W);
58 prt_tests(lm4);
59
60
61
62
63

```

---

```

64
65
66 % spatial fixed effects + (robust) LM tests for spatial lag and
    spatial error model
67 % fixed effects, within estimator
68 % demeaning of the y and x variables
69
70 model=1;
71 [ywith ,xwith ,meanny ,meannx ,meanty ,meantx]=demean(y ,x ,N ,T ,model) ;
72 results=ols(ywith ,xwith) ;
73 vnames=strvcat('logSMR','tasa_nat','ratio_act','energia_vial','PIB
    ');
74 prt_reg(results ,vnames);
75 intercept=mean(y)-mean(x)*results.beta ;
76 sfe=meanny-meannx*results.beta ; % including the constant term
77 yme = y - mean(y) ;
78 et=ones(T,1) ;
79 error=y-kron(et ,sfe)-x*results.beta ;
80 rsqr1 = error' * error ;
81 rsqr2 = yme' * yme ;
82 FE_rsqr2 = 1.0 - rsqr1/rsqr2 % r-squared including fixed effects
83 sige=results.sige*((nobs-K)/nobs) ;
84 logliksfe=-nobs/2*log(2*pi*sige)-1/(2*sige)*results.resid'*results
    .resid
85 LMsarsem_panel(results ,W ,ywith ,xwith) ; % (Robust) LM tests
86
87 lm1=lmlag_panel(ywith ,xwith ,W) ;
88 prt_tests(lm1) ;
89
90 lm2=lmerror_panel(ywith ,xwith ,W) ;
91 prt_tests(lm2) ;
92
93 lm3=lmlag_robust_panel(ywith ,xwith ,W) ;
94 prt_tests(lm3) ;
95
96 lm4=lmerror_robust_panel(ywith ,xwith ,W) ;
97 prt_tests(lm4) ;
98
99
100
101
102
103
104
105
106

```

```

107
108
109 %time-period fixed effects + (robust) LM tests for spatial lag
      and spatial error model
110 %fixed effects , within estimator
111 %demeaning of the y and x variables
112
113 model=2;
114 [ywith ,xwith ,meanny ,meannx ,meanty ,meantx]=demean(y,x,N,T,model);
115 results=ols(ywith ,xwith );
116 vnames=strvcat('logSMR','tasa_nat','ratio_act','energia_vial','PIB
      '); %should be changed if x is changed
117 prt_reg(results ,vnames);
118 intercept=mean(y)-mean(x)*results.beta;
119 tfe=meanty-meantx*results.beta; %including the constant term
120 yme = y - mean(y);
121 en=ones(N,1);
122 error=y-kron(tfe ,en)-x*results.beta;
123 rsqr1 = error'*error;
124 rsqr2 = yme'*yme;
125 FE_rsqr2 = 1.0 - rsqr1/rsqr2 %r-squared including fixed effects
126 sige=results.sige*((nobs-K)/nobs);
127 logliktfe=-nobs/2*log(2*pi*sige)-1/(2*sige)*results.resid'*results
      .resid
128 LMsarsem_panel(results ,W,ywith ,xwith ); %(Robust) LM tests
129
130 lm1=lmlag_panel(ywith ,xwith ,W);
131 prt_tests(lm1);
132
133 lm2=lmerror_panel(ywith ,xwith ,W);
134 prt_tests(lm2);
135
136 lm3=lmlag_robust_panel(ywith ,xwith ,W);
137 prt_tests(lm3);
138
139 lm4=lmerror_robust_panel(ywith ,xwith ,W);
140 prt_tests(lm4);
141
142
143
144
145
146
147
148
149

```



---

```

150
151
152
153
154 % spatial and time period fixed effects + (robust) LM tests for
      spatial lag and spatial error model
155 % fixed effects , within estimator
156 % demeaning of the y and x variables
157
158 model=3;
159 [ywith ,xwith ,meanny ,meannx ,meanty ,meantx]=demean(y ,x ,N ,T ,model) ;
160 results=ols(ywith ,xwith) ;
161 vnames=strcat('logSMR' , 'tasa_nat' , 'ratio_act' , 'energia_vial' , 'PIB
      '); % should be changed if x is changed
162 prt_reg(results ,vnames) ;
163 intercept=mean(y)-mean(x)*results.beta ;
164 sfe=meanny-meannx*results.beta-kron(en ,intercept) ;
165 tfe=meanty-meantx*results.beta-kron(et ,intercept) ;
166 yme = y - mean(y) ;
167 ent=ones(N*T,1) ;
168 error=y-kron(tfe ,en)-kron(et ,sfe)-x*results.beta-kron(ent ,
      intercept) ;
169 rsqr1 = error'*error ;
170 rsqr2 = yme'*yme ;
171 FE_rsqr2 = 1.0 - rsqr1/rsqr2 % r-squared including fixed effects
172 sige=results.sige*((nobs-K)/nobs) ;
173 loglikstfe=-nobs/2*log(2*pi*sige)-1/(2*sige)*results.resid'*
      results.resid
174
175 LMsarsem_panel(results ,W ,ywith ,xwith) ; % (Robust) LM tests
176
177 lm1=lmlag_panel(ywith ,xwith ,W) ;
178 prt_tests(lm1) ;
179
180 lm2=lmerror_panel(ywith ,xwith ,W) ;
181 prt_tests(lm2) ;
182
183 lm3=lmlag_robust_panel(ywith ,xwith ,W) ;
184 prt_tests(lm3) ;
185
186 lm4=lmerror_robust_panel(ywith ,xwith ,W) ;
187 prt_tests(lm4) ;
188
189
190
191

```

```
192
193
194
195 % Tests for the joint significance of spatial and/or time-period
      fixed effects
196 LR=-2*(logliktfe-loglikstfe);
197 dof=N;
198 probability=1-chis_prb(LR,dof);
199 % Note: probability > 0.05 implies rejection of spatial fixed
      effects
200 fprintf(1,'LR-test joint significance spatial fixed effects,
      degrees of freedom and probability = %9.4f,%6d,%9.4f \n',LR,dof
      ,probability);
201 LR=-2*(logliksfe-loglikstfe);
202 dof=T;
203 probability=1-chis_prb(LR,dof);
204 % Note: probability > 0.05 implies rejection of spatial fixed
      effects
205 fprintf(1,'LR-test joint significance time-periode fixed effects,
      degrees of freedom and probability = %9.4f,%6d,%9.4f \n',LR,dof
      ,probability);
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
```

---

```

231 % 1) Direct/Indirect effect estimates of the explanatory variables
232 % LeSage JP, Pace RK (2009) Introduction to Spatial Econometrics.
      Boca Raton, Taylor & Francis Group.
233 % routine direct_indirect_effects_estimates(results,W,spat_model)
      is written by J.P. Elhorst
234 % routines panel_effects_sar(results,vnames,W) and
      panel_effects_sar(results,vnames,W)
235 % are written and made available by D. Lacombe
236 % User may use both routines (note: results are slightly different
      from each other since they are based on draws from a
      distribution
237 % or choose one particular routine. If N is large, user should
      choose
238 % Lacombe's routines, since this one is much more efficient
      computationally
239
240 % 2) Bias correction of coefficient estimates
241 % Lee Lf, Yu J. (2010) Estimation of spatial autoregressive models
      with
242 % fixed effects, Journal of Econometrics 154: 165–185.
243
244 % 3) Selection framework to determine which spatial panel data
      model best
245 % describes the data.
246
247 % add the directory with our subroutines to the search list
248
249 addpath(pwd);
250 % dimensions of the problem
251 A=xlsread('datos.xlsx');
252 W1=xlsread('matriz_conect.xlsx');
253 T=20; % number of time periods
254 N=26; % number of regions
255 % row-normalize W
256 W=normw(W1); % function of LeSage
257 y=A(:,[5]); % column number in the data matrix that corresponds to
      the dependent variable
258 x=A(:,[8,9,10]); % column numbers in the data matrix that
      correspond to the independent variables
259
260 for t=1:T
261     t1=(t-1)*N+1;t2=t*N;
262     wx(t1:t2,:)=W*x(t1:t2,:);
263 end
264 xconstant=ones(N*T,1);
265 [nobs K]=size(x);

```

```

266
267 %-----
268 %No fixed effects + spatially lagged dependent variable
269 info.lflag=0; %required for exact results
270 info.model=0;
271 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
272 %New routines to calculate effects estimates
273 results=sar_panel_FE(y,[xconstant x],W,T,info);
274 vnames=strvcat('logSMR','intercepto','ratio_act','energia_vial','
    PIB');
275 %Print out coefficient estimates
276 prt_sp(results,vnames,1);
277 %Print out effects estimates
278 spat_model=0;
279 direct_indirect_effects_estimates(results,W,spat_model);
280 panel_effects_sar(results,vnames,W);
281
282 %-----
283
284 %No fixed effects + spatially lagged dependent variable +
    spatially
285 %independent variables
286 info.lflag=1; %required for exact results
287 info.model=0;
288 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
289 %New routines to calculate effects estimates
290 results=sar_panel_FE(y,[xconstant x wx],W,T,info);
291 vnames=strvcat('logSMR','intercepto','ratio_act','energia_vial','
    PIB','W*ratio_act','W*energia_vial','W*PIB');
292 %Print out coefficient estimates
293 prt_sp(results,vnames,1);
294 %Print out effects estimates
295 spat_model=1;
296 direct_indirect_effects_estimates(results,W,spat_model);
297 panel_effects_sdm(results,vnames,W);
298
299
300
301
302
303
304
305
306

```

---

```

307
308
309 % Spatial fixed effects + spatially lagged dependent variable
310 info.lflag=0; %required for exact results
311 info.model=1;
312 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
313 %New routines to calculate effects estimates
314 results=sar_panel_FE(y,x,W,T,info);
315 vnames=strvcat('logSMR', 'intercepto','ratio_act','energia_vial','
    PIB');
316 %Print out coefficient estimates
317 prt_sp(results,vnames,1);
318 %Print out effects estimates
319 spat_model=0;
320 direct_indirect_effects_estimates(results,W,spat_model);
321 panel_effects_sar(results,vnames,W);
322
323
324
325 % Spatial fixed effects + spatially lagged dependent variable +
    spatially
326 %independent variables
327 info.lflag=0; %required for exact results
328 info.model=1;
329 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
330 %New routines to calculate effects estimates
331 results=sar_panel_FE(y,[x wx],W,T,info);
332 vnames=strvcat('logSMR', 'ratio_act','energia_vial','PIB','W*
    ratio_act','W*energia_vial','W*PIB');
333 %Print out coefficient estimates
334 prt_sp(results,vnames,1);
335 %Print out effects estimates
336 spat_model=1;
337 direct_indirect_effects_estimates(results,W,spat_model);
338 panel_effects_sdm(results,vnames,W);
339
340
341
342
343
344
345
346
347

```

---

```

348
349
350 %Time period fixed effects + spatially lagged dependent variable
351 info.lflag=0; %required for exact results
352 info.model=2;
353 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
354 %New routines to calculate effects estimates
355 results=sar_panel_FE(y,x,W,T,info);
356 vnames=strvcat('logSMR','intercepto','ratio_act','energia_vial','
    PIB');
357 %Print out coefficient estimates
358 prt_sp(results,vnames,1);
359 %Print out effects estimates
360 spat_model=0;
361 direct_indirect_effects_estimates(results,W,spat_model);
362 panel_effects_sar(results,vnames,W);
363
364
365
366 %Time period fixed effects + spatially lagged dependent variable
    + spatially
367 %independent variables
368 info.lflag=0; %required for exact results
369 info.model=2;
370 info.fe=1; %Do not print intercept and fixed effects; use info.fe
    =1 to turn on
371 %New routines to calculate effects estimates
372 results=sar_panel_FE(y,[x wx],W,T,info);
373 vnames=strvcat('logSMR','ratio_act','energia_vial','PIB','W*
    ratio_act','W*energia_vial','W*PIB');
374 %Print out coefficient estimates
375 prt_sp(results,vnames,1);
376 %Print out effects estimates
377 spat_model=1;
378 direct_indirect_effects_estimates(results,W,spat_model);
379 panel_effects_sdm(results,vnames,W);
380
381
382
383
384
385
386
387
388

```

---

```

389
390
391 % Spatial and time period fixed effects + spatially lagged
      dependent variable
392 info.lflag=1; %required for exact results
393 info.model=3;
394 info.fe=1; %Do not print intercept and fixed effects; use info.fe
      =1 to turn on
395 %New routines to calculate effects estimates
396 results=sar_panel_FE(y,x,W,T,info);
397 vnames=strvcat('logSMR', 'intercepto','ratio_act','energia_vial','
      PIB');
398 % Print out coefficient estimates
399 prt_sp(results ,vnames,1);
400 % Print out effects estimates
401 spat_model=0;
402 direct_indirect_effects_estimates(results ,W,spat_model);
403 panel_effects_sar(results ,vnames,W);
404
405
406
407 % Spatial and time period fixed effects + spatially lagged
      dependent variable + spatially
408 % independent variables
409 %SDM
410
411 info.lflag=0; %required for exact results
412 info.model=3;
413 info.fe=1; %Do not print intercept and fixed effects; use info.fe
      =1 to turn on
414 info.bc=1;
415 %New routines to calculate effects estimates
416 results=sar_panel_FE(y,[x wx],W,T,info);
417 vnames=strvcat('logSMR', 'ratio_act','energia_vial','PIB');
418 % Print out coefficient estimates
419 prt_sp(results ,vnames,1);
420 % Print out effects estimates
421 spat_model=1;
422 direct_indirect_effects_estimates(results ,W,spat_model);
423 panel_effects_sdm(results ,vnames,W);
424 %Wald test for spatial lag model
425 btemp=results.parm;
426 varcov=results.cov;
427 Rafg=zeros(K,2*K+2);
428 for k=1:K
429     Rafg(k,K+k)=1; %R(1,3)=0 and R(2,4)=0;

```

---

```

430 end
431 Wald_spatial_lag=(Rafg*btemp) '* inv (Rafg*varcov*Rafg ') *Rafg*btemp
432 prob_spatial_lag= 1-chis_cdf (Wald_spatial_lag , K) % probability
    greater than 0.05 points to insignificance
433 %LR test spatial Durbin model against spatial lag model (requires
434 %estimation results of the spatial lag model to be available)
435 resultssar=sar_panel_FE(y,x,W,T,info);
436 LR_spatial_lag=-2*(resultssar.lik-results.lik)
437 prob_spatial_lag=1-chis_cdf (LR_spatial_lag,K) % probability
    greater than 0.05 points to insignificance
438 %Wald test for spatial error model
439 R=zeros(K,1);
440 for k=1:K
441     R(k)=btemp(2*K+1)*btemp(k)+btemp(K+k);
442 end
443 Rafg=zeros(K,2*K+2);
444 for k=1:K
445     Rafg(k,k) =btemp(2*K+1);
446     Rafg(k,K+k) =1;
447     Rafg(k,2*K+1)=btemp(k);
448 end
449 Wald_spatial_error=R' * inv (Rafg*varcov*Rafg ') *R
450 prob_spatial_error= 1-chis_cdf (Wald_spatial_error ,K) %
    probability greater than 0.05 points to insignificance
451 %LR test spatial Durbin model against spatial error model (
    requires
452 %estimation results of the spatial error model to be available)
453 resultsssem=sem_panel_FE(y,x,W,T,info);
454 LR_spatial_error=-2*(resultsssem.lik-results.lik)
455 prob_spatial_error=1-chis_cdf (LR_spatial_error ,K) % probability
    greater than 0.05 points to insignificance
456 %needed for Hausman test later on
457 logliklag=results.lik;
458 blagfe=results.parm(1:end-1);
459 covblagfe=results.cov(1:end-1,1:end-1);
460
461
462
463
464
465
466
467
468
469
470

```



---

```

471
472
473 % Spatial random effects and time period fixed effects + spatially
      lagged dependent variable + spatially
474 % independent variables
475 [ywith ,xwith ,meanny ,meannx ,meanty ,meantx]=demean(y,[x wx],N,T,2);
476 info.model=1;
477 results=sar_panel_RE(ywith ,xwith ,W,T, info);
478 prt_sp(results ,vnames,1);
479 % Print out effects estimates
480 spat_model=1;
481 info.lflag=1; % required for exact results
482 direct_indirect_effects_estimates(results ,W,spat_model);
483 panel_effects_sdm(results ,vnames,W);
484 % Wald test for spatial lag model
485 btemp=results.parm(1:2*K+2);
486 varcov=results.cov(1:2*K+2,1:2*K+2);
487 Rafg=zeros(K,2*K+2);
488 for k=1:K
489     Rafg(k,K+k)=1; %R(1,3)=0 and R(2,4)=0;
490 end
491 Wald_spatial_lag=(Rafg*btemp)'*inv(Rafg*varcov*Rafg')*Rafg*btemp
492 prob_spatial_lag=1-chis_cdf(Wald_spatial_lag,K);
493 %LR test spatial Durbin model against spatial lag model (requires
494 % estimation results of the spatial lag model to be available)
495 resultssar=sar_panel_RE(ywith ,xwith(:,1:K),W,T,info);
496 LR_spatial_lag=-2*(resultssar.lik-results.lik)
497 prob_spatial_lag=1-chis_cdf(LR_spatial_lag,K)
498 % Wald test for spatial error model
499 R=zeros(K,1);
500 for k=1:K
501     R(k)=btemp(2*K+1)*btemp(k)+btemp(K+k);
502
503 end
504 Rafg=zeros(K,2*K+2);
505 for k=1:K
506     Rafg(k,k) =btemp(2*K+1);
507     Rafg(k,K+k) =1;
508     Rafg(k,2*K+1)=btemp(k);
509 end
510 Wald_spatial_error=R'*inv(Rafg*varcov*Rafg')*R
511 prob_spatial_error=1-chis_cdf(Wald_spatial_error,K); %
      probability greater than 0.05 points to insignificance
512 %LR test spatial Durbin model against spatial error model (
      requires
513 % estimation results of the spatial error model to be available

```

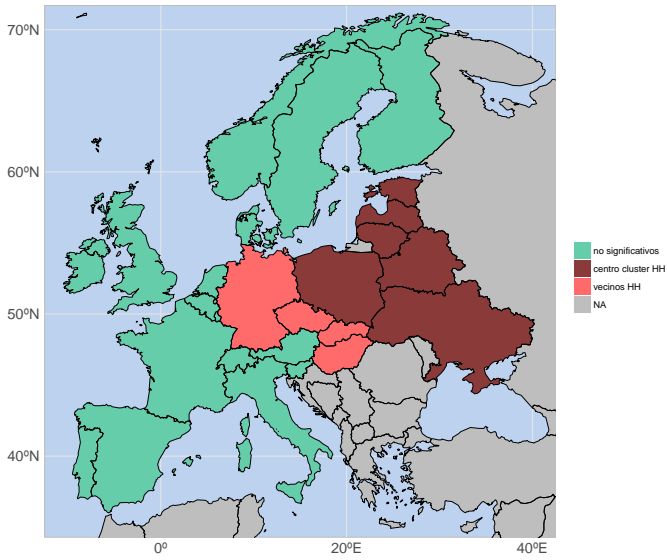
```

514  resultsssem=sem_panel_RE(ywith,xwith(:,1:K),W,T,info);
515  LR_spatial_error=-2*(resultsssem.lik-results.lik)
516  prob_spatial_error=1-chis_cdf(LR_spatial_error,K) % probability
      greater than 0.05 points to insignificance
517  % needed for Hausman test later on
518  logliklagre=results.lik;
519  blagre=results.parm(1:end-2);
520  covblagre=results.cov(1:end-2,1:end-2);
521
522  _____
523
524  % Hausman test FE versus RE
525  hausman=(blagfe-blagre)'*inv(covblagre-covblagfe)*(blagfe-blagre);
526  dof=length(blagfe);
527  probability=1-chis_prb(abs(hausman),dof);
528  % Note: probability < 0.025 implies rejection of random effects
      model in favor of fixed effects model
529  % Use 0.025, since it is a one-sided test
530  fprintf(1,'Hausman test-statistic, degrees of freedom and
      probability = %9.4f,%6d,%9.4f \n',abs(hausman),dof,probability)
      ;

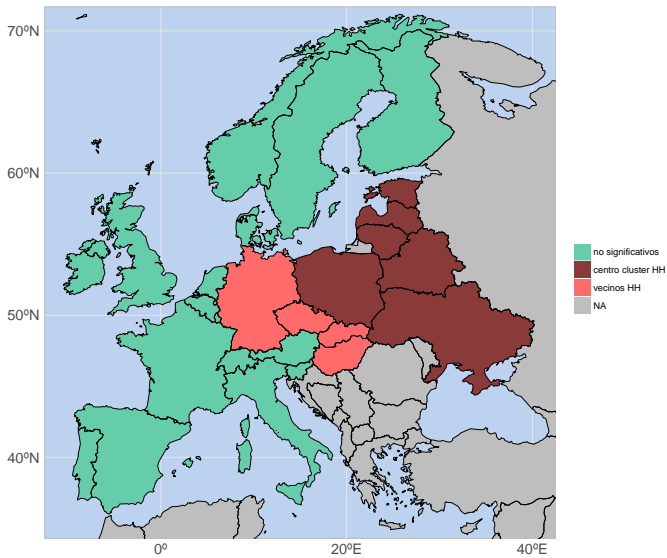
```

## Apéndice C

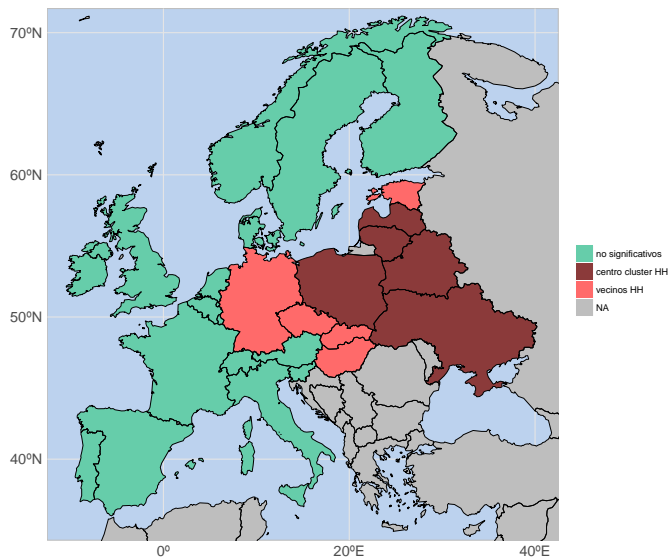
# Mapas LISA de personas entre 0-14 años ( $g_1$ )



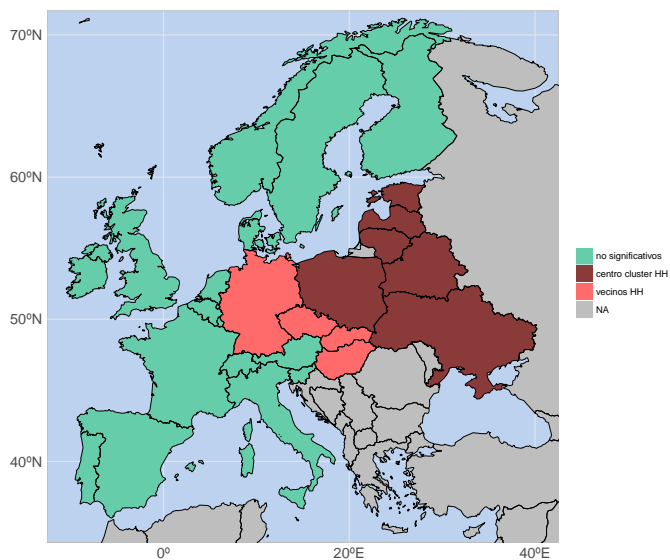
**Figura C.1** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1990.




**Figura C.2** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1990.




**Figura C.3** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1991.



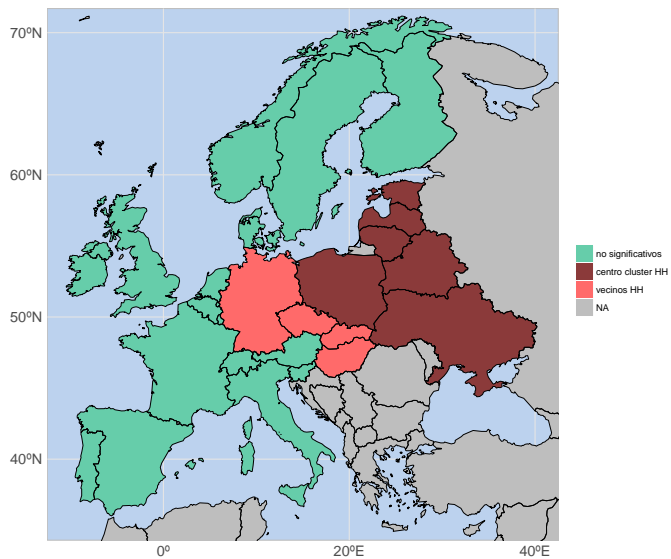
**Figura C.4** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1991.



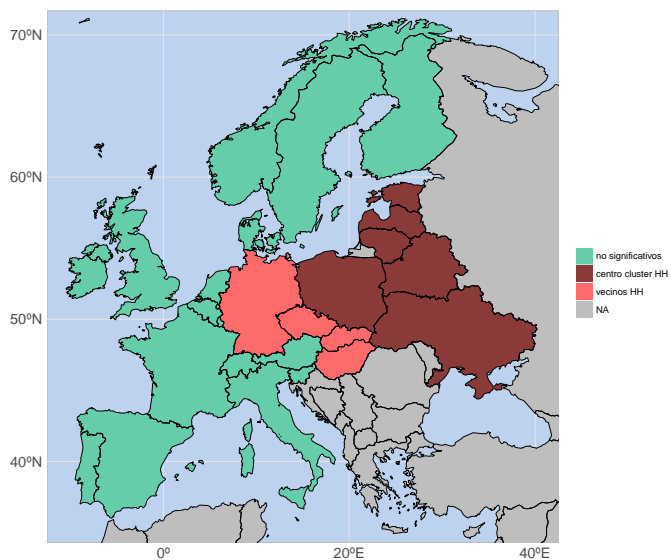
**Figura C.5** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1992.




**Figura C.6** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1992.




**Figura C.7** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1993.



**Figura C.8** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1993.




**Figura C.9** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1994.




**Figura C.10** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1994.






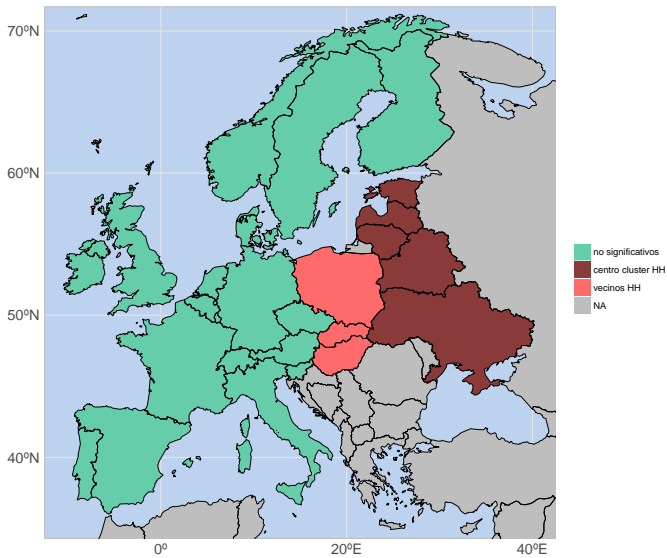
**Figura C.11** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1995.




**Figura C.12** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1995.




**Figura C.13** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1996.



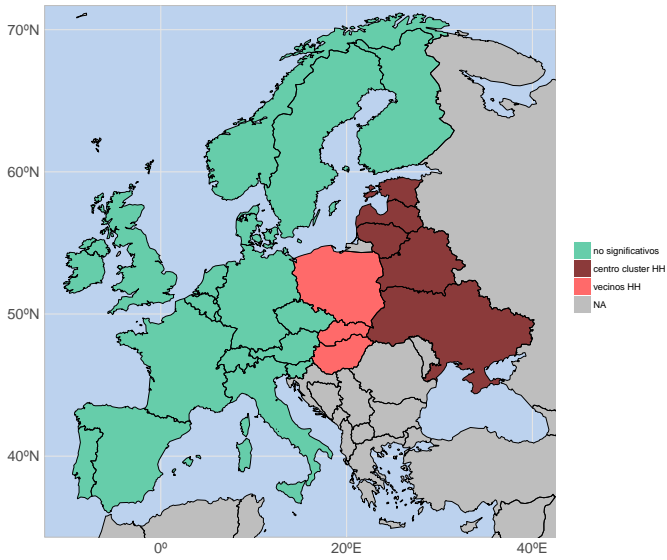
**Figura C.14** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1996.




**Figura C.15** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1997.




**Figura C.16** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1997.



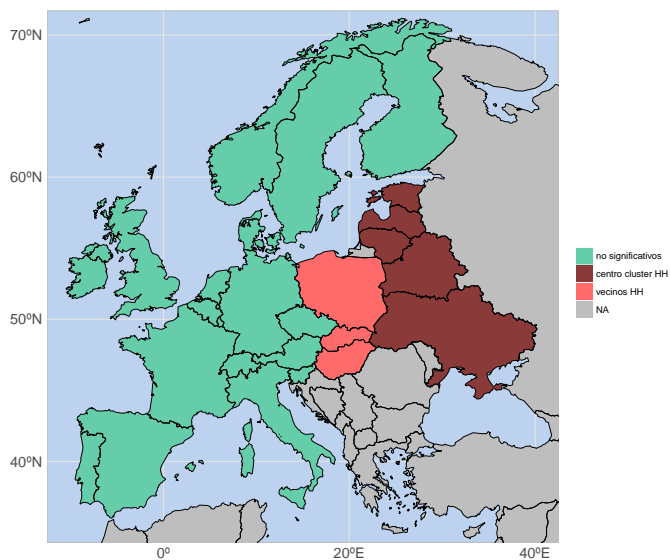
**Figura C.17** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1998.




**Figura C.18** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1998.




**Figura C.19** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 1999.



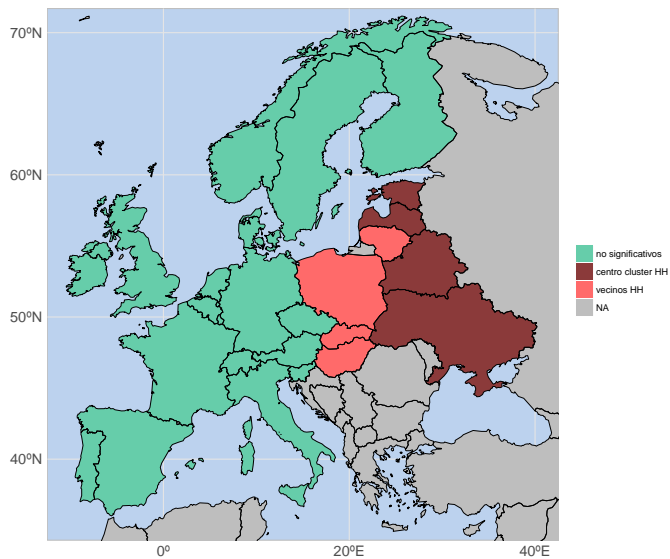
**Figura C.20** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 1999.




**Figura C.21** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2000.




**Figura C.22** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2000.




**Figura C.23** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2001.



**Figura C.24** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2001.




**Figura C.25** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2002.




**Figura C.26** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2002.







**Figura C.27** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2003.



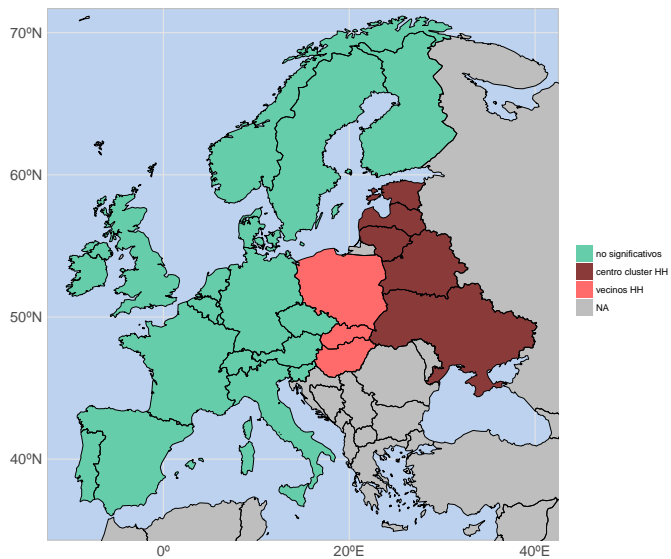
**Figura C.28** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2003.



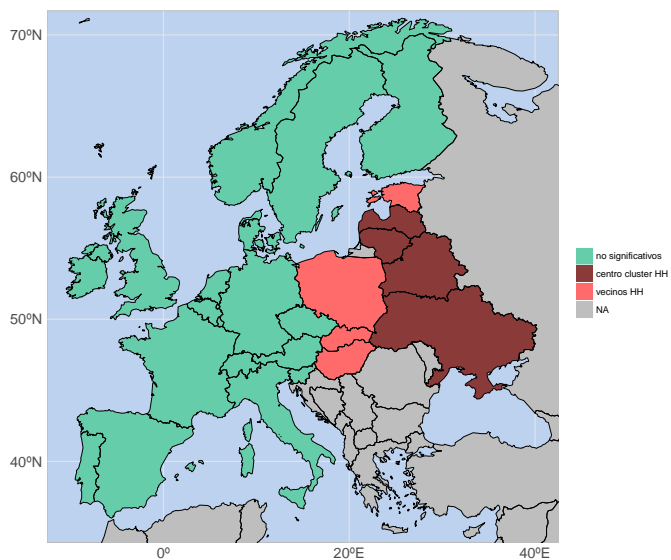
**Figura C.29** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2004.



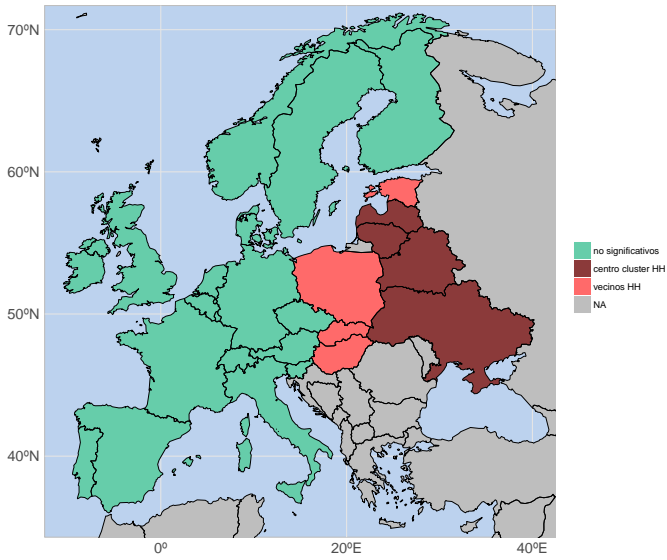
**Figura C.30** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2004.



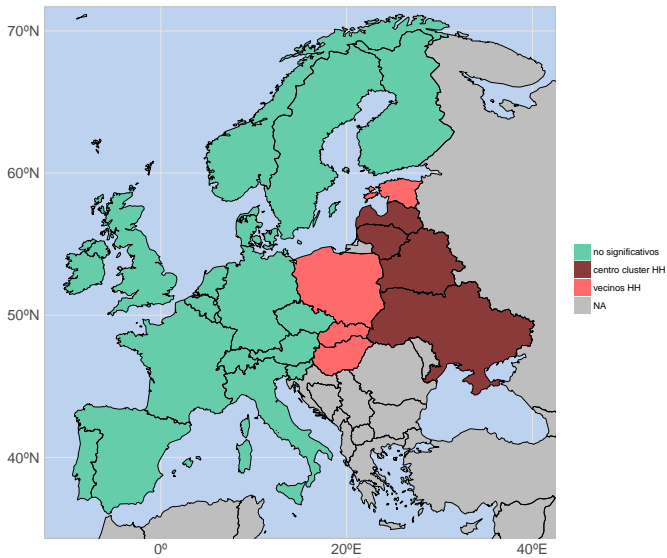
**Figura C.31** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2005.



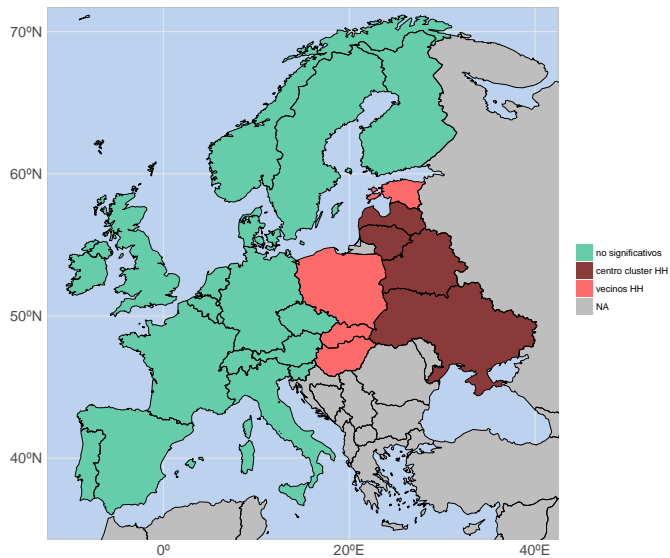
**Figura C.32** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2005.



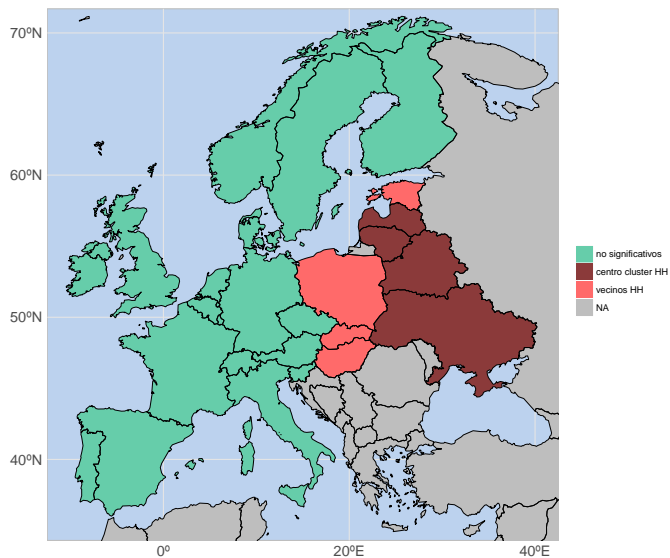
**Figura C.33** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2006.



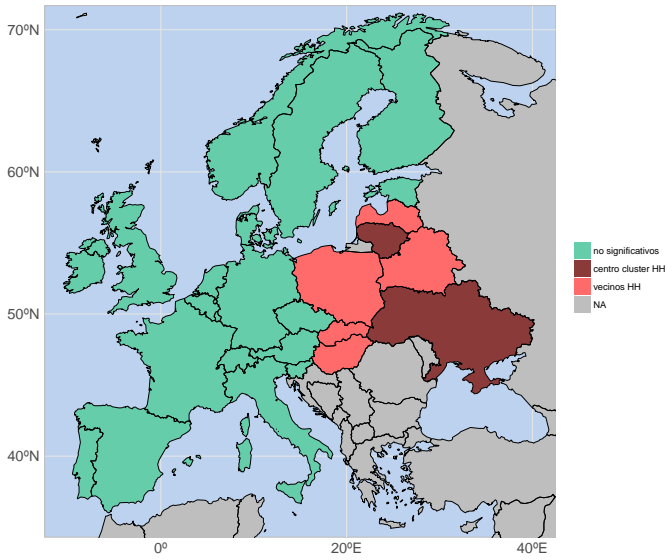
**Figura C.34** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2006.




**Figura C.35** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2007.



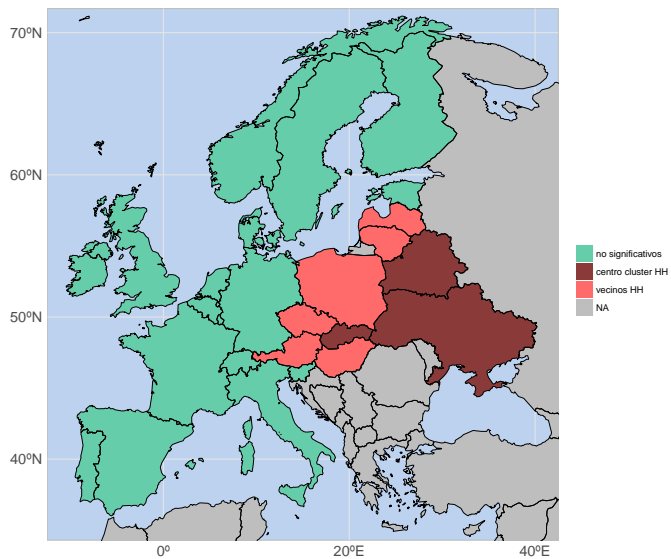
**Figura C.36** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2007.




**Figura C.37** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2008.



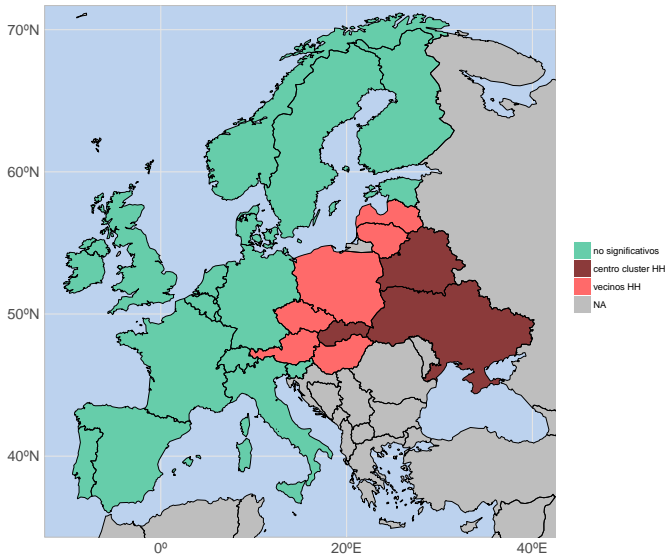
**Figura C.38** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2008.



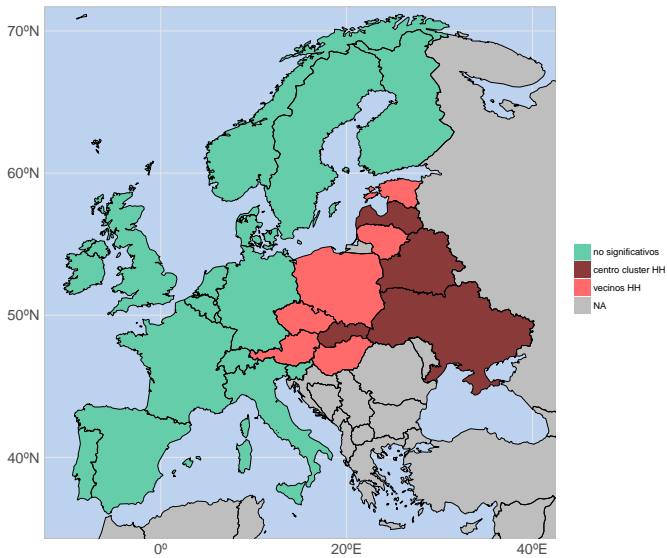
**Figura C.39** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2009.



**Figura C.40** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2009.

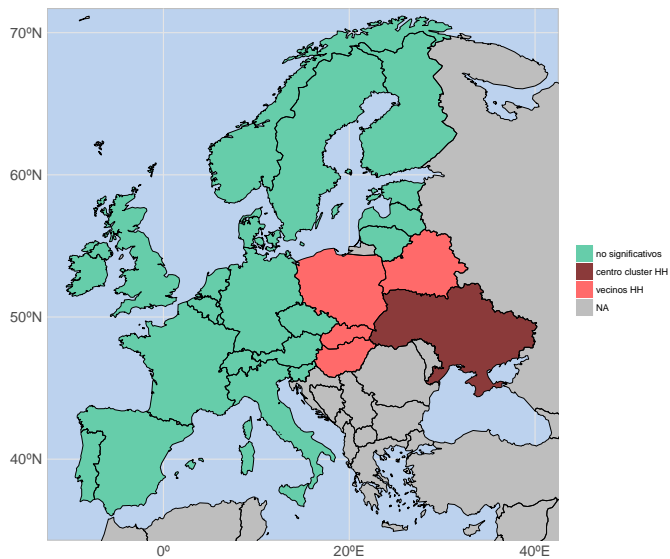


**Figura C.41** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2010.

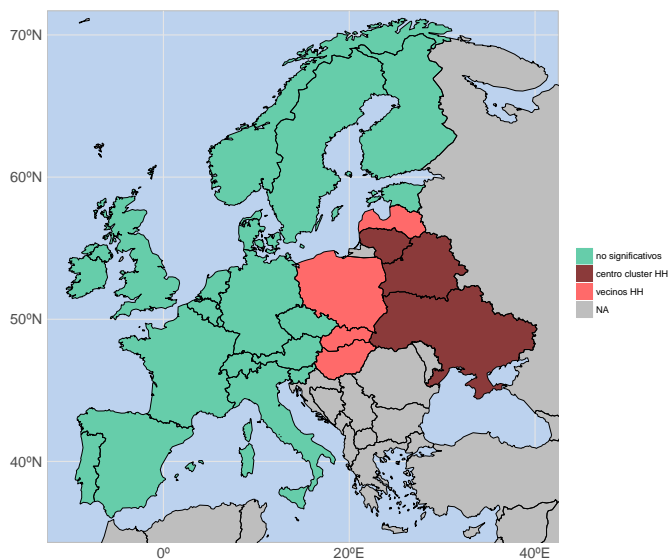


**Figura C.42** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2010.

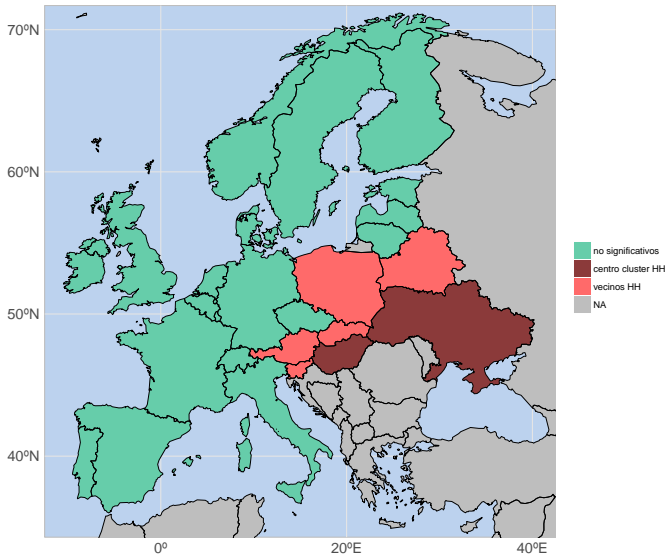




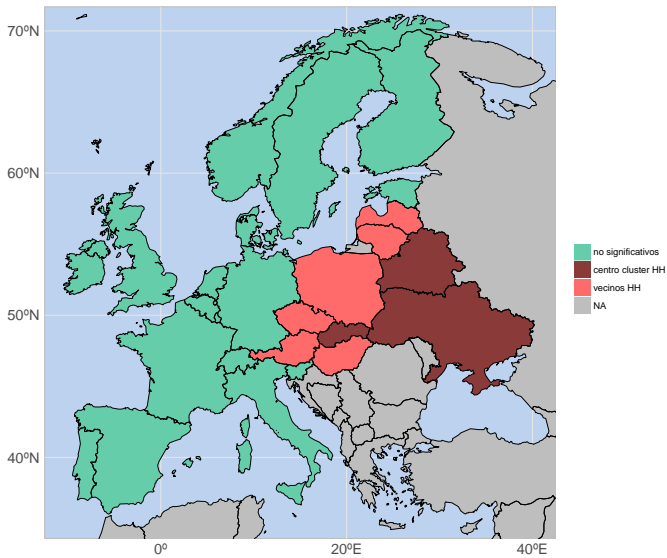
**Figura C.43** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2011.



**Figura C.44** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2011.



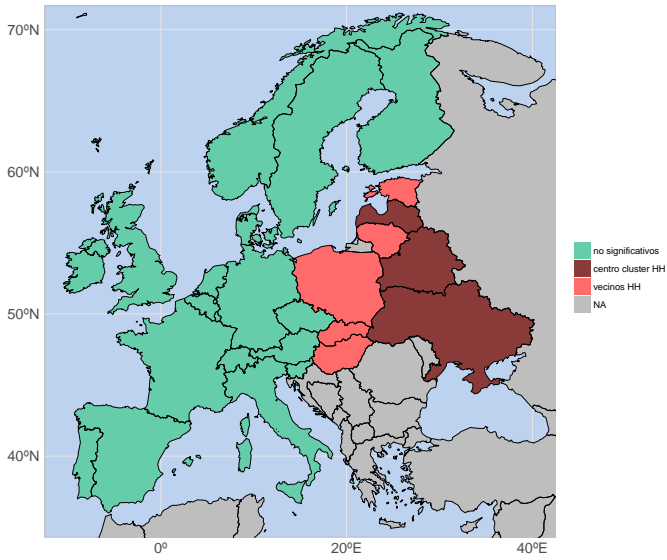
**Figura C.45** Mapa de clusters significativos LISA para las mujeres entre 0 y 14 años, en el año 2012.



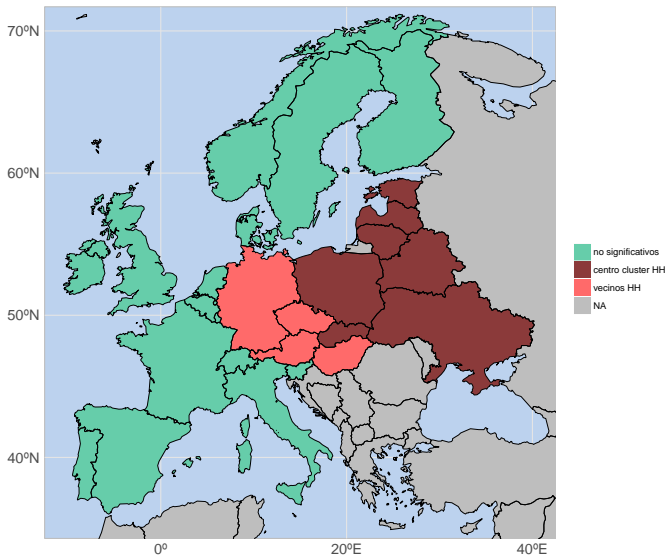
**Figura C.46** Mapa de clusters significativos LISA para los hombres entre 0 y 14 años, en el año 2012.

## Apéndice D

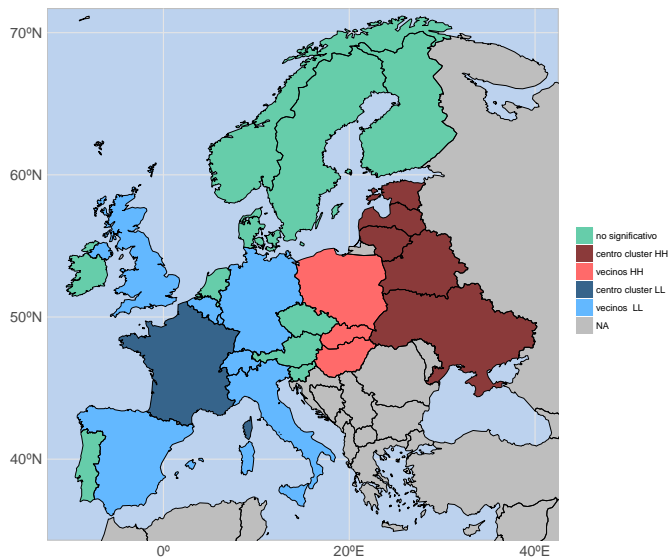
# Mapas LISA de personas entre 15-64 años ( $g_2$ )



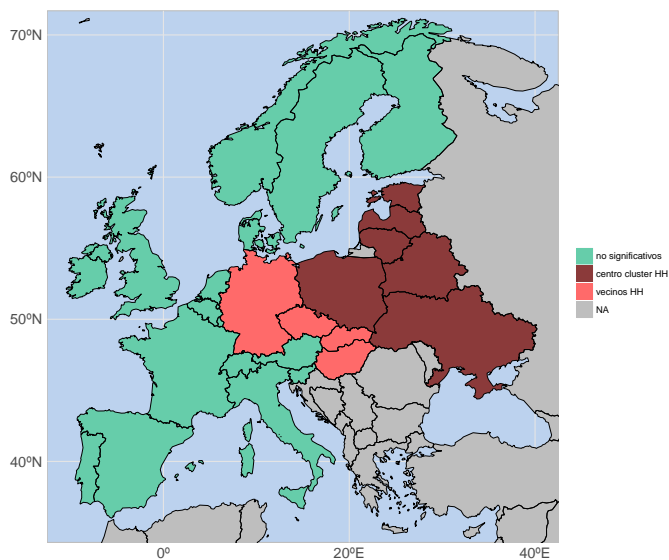
**Figura D.1** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1990.




**Figura D.2** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1990.




**Figura D.3** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1991.



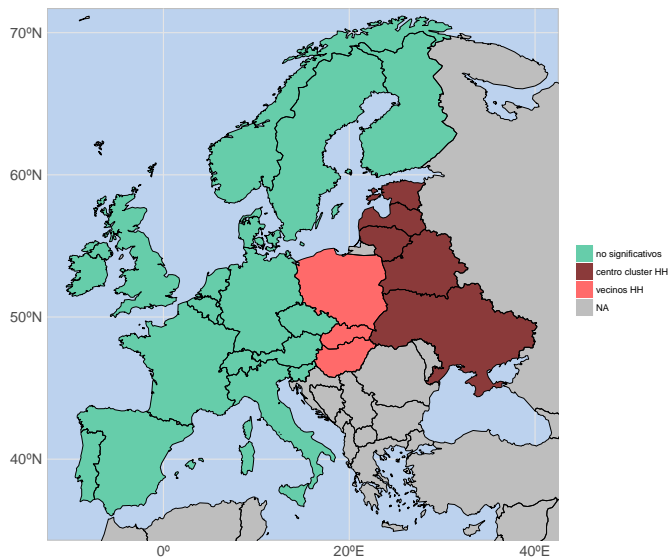
**Figura D.4** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1991.




**Figura D.5** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1992.




**Figura D.6** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1992.




**Figura D.7** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1993.



**Figura D.8** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1993.




**Figura D.9** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1994.




**Figura D.10** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1994.






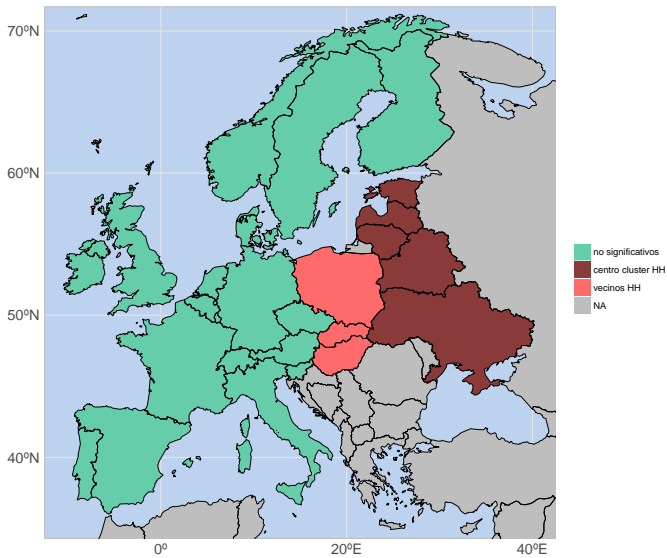
**Figura D.11** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1995.




**Figura D.12** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1995.




**Figura D.13** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1996.



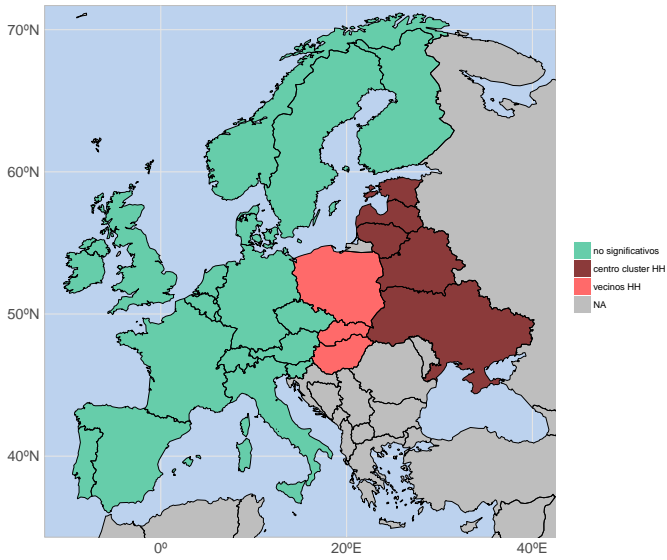
**Figura D.14** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1996.




**Figura D.15** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1997.



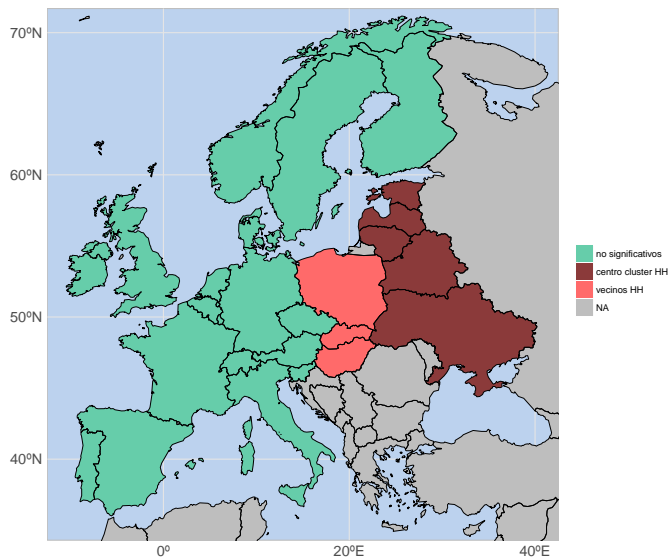
**Figura D.16** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1997.



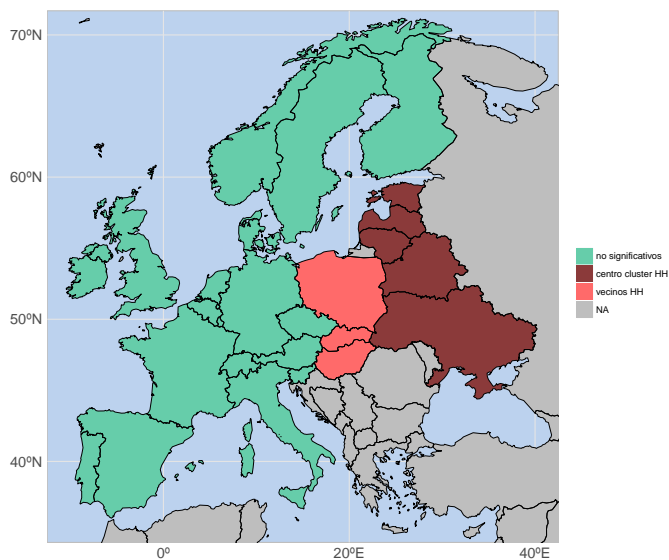
**Figura D.17** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1998.



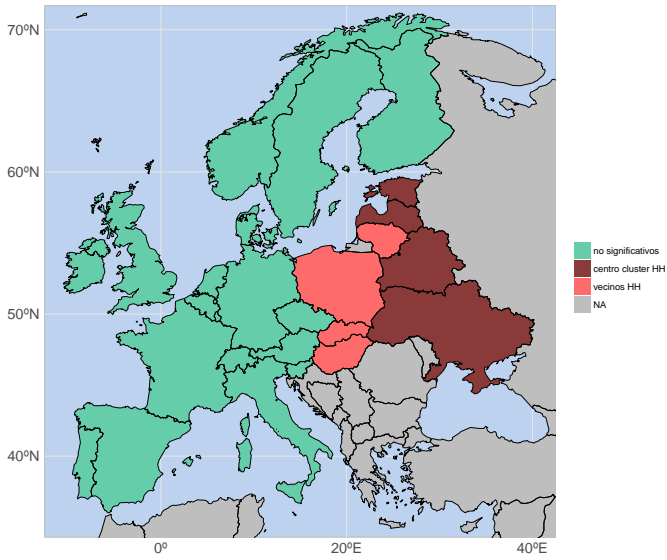
**Figura D.18** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1998.




**Figura D.19** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 1999.



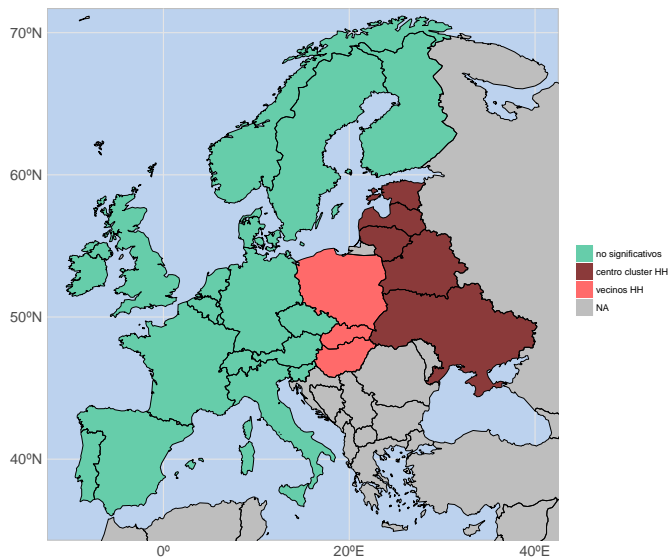
**Figura D.20** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 1999.




**Figura D.21** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2000.




**Figura D.22** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2000.




**Figura D.23** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2001.



**Figura D.24** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2001.




**Figura D.25** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2002.




**Figura D.26** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2002.







**Figura D.27** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2003.



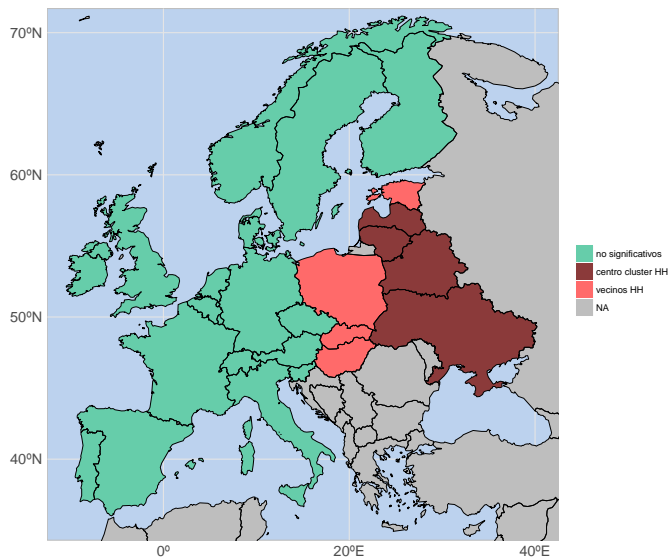
**Figura D.28** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2003.




**Figura D.29** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2004.



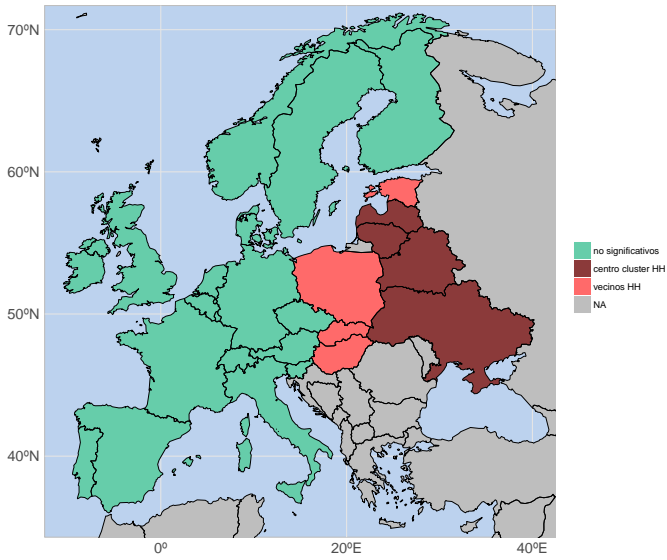
**Figura D.30** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2004.




**Figura D.31** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2005.




**Figura D.32** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2005.



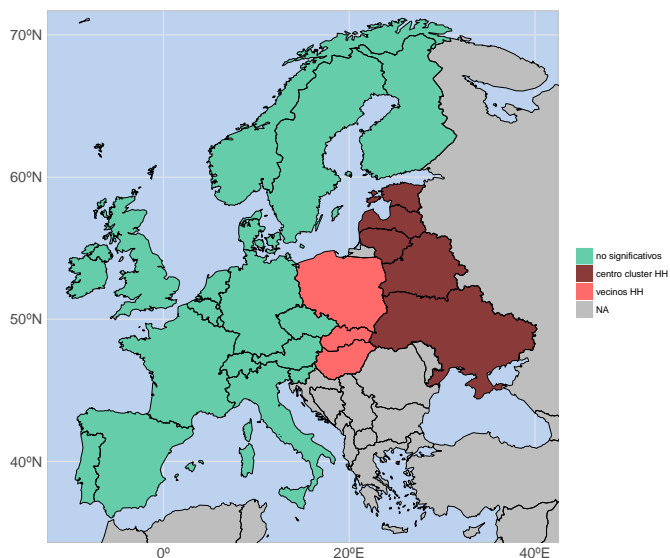
**Figura D.33** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2006.




**Figura D.34** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2006.




**Figura D.35** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2007.




**Figura D.36** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2007.



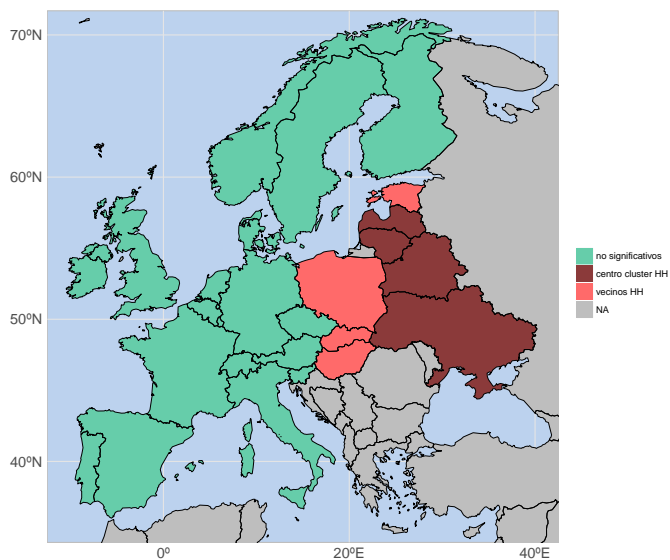
**Figura D.37** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2008.




**Figura D.38** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2008.




**Figura D.39** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2009.



**Figura D.40** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2009.

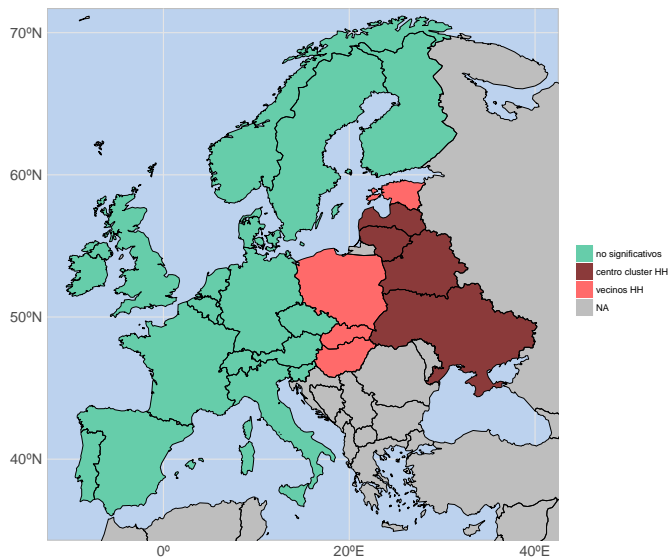


**Figura D.41** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2010.

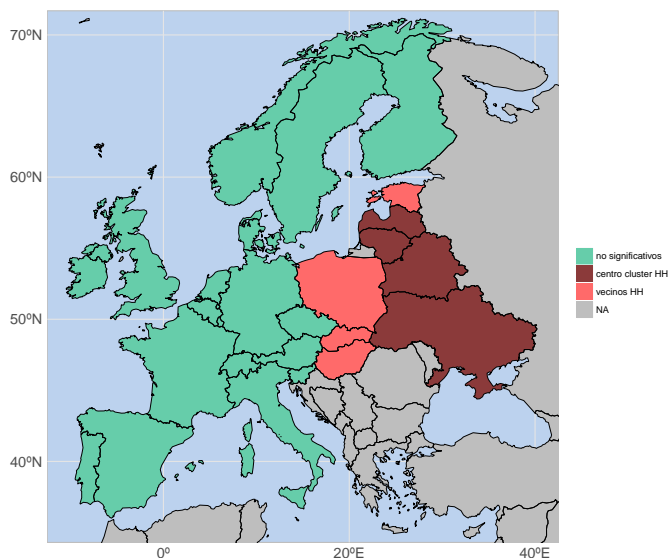


**Figura D.42** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2010.

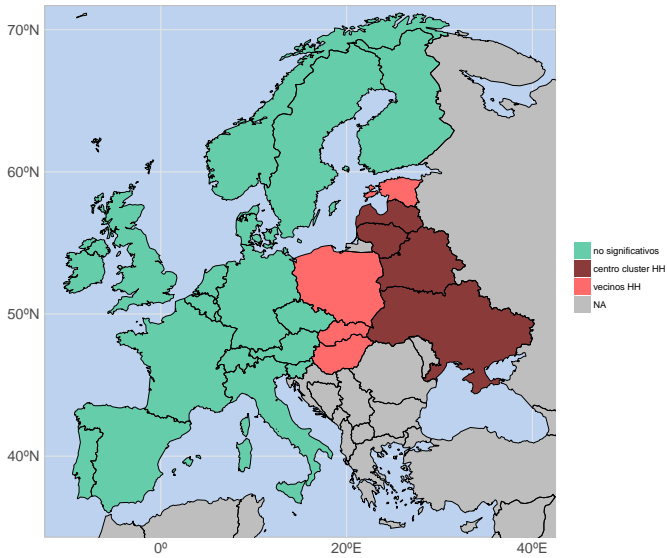





**Figura D.43** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2011.



**Figura D.44** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2011.



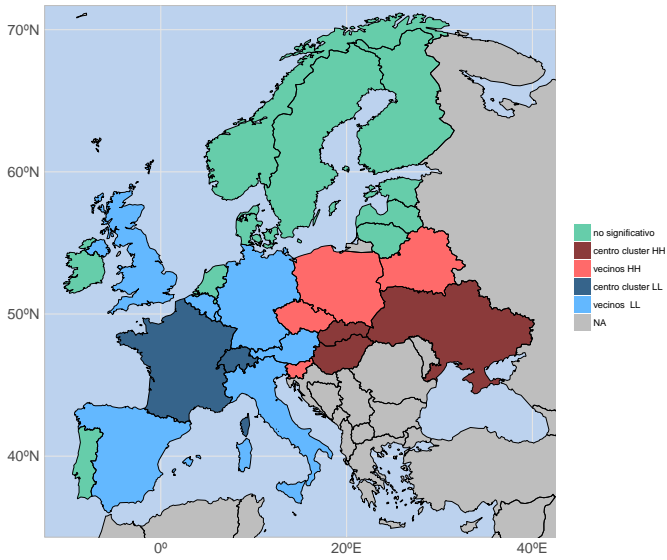
**Figura D.45** Mapa de clusters significativos LISA para las mujeres entre 15 y 64 años, en el año 2012.



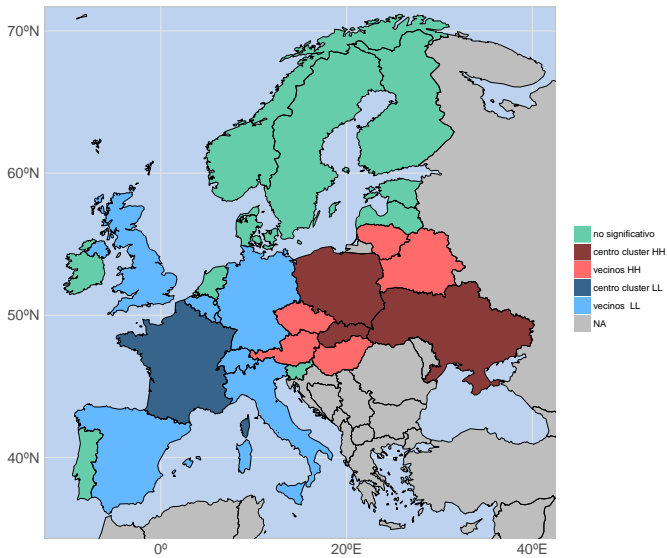
**Figura D.46** Mapa de clusters significativos LISA para los hombres entre 15 y 64 años, en el año 2012.

## Apéndice E

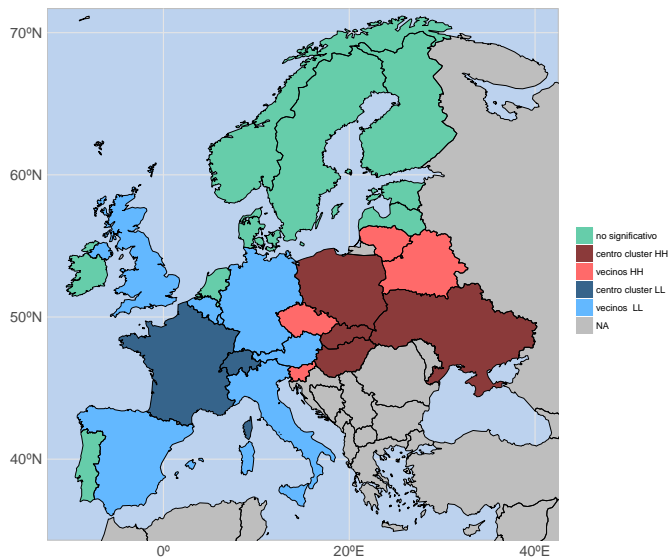
# Mapas LISA de personas entre 65-110+ años ( $g_3$ )



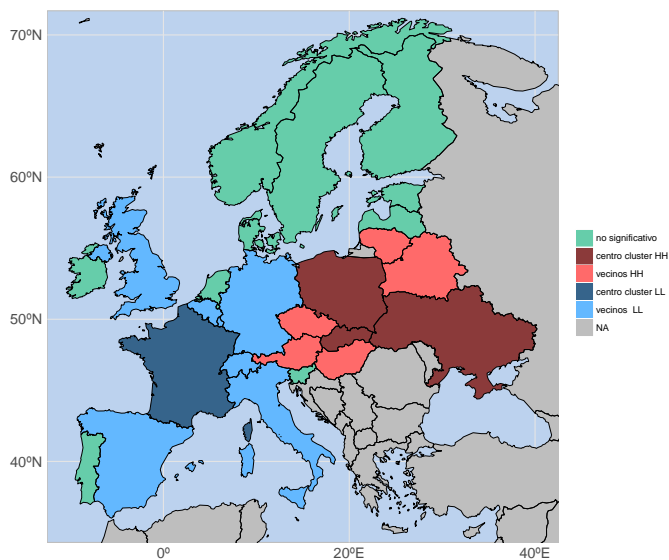
**Figura E.1** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1990.



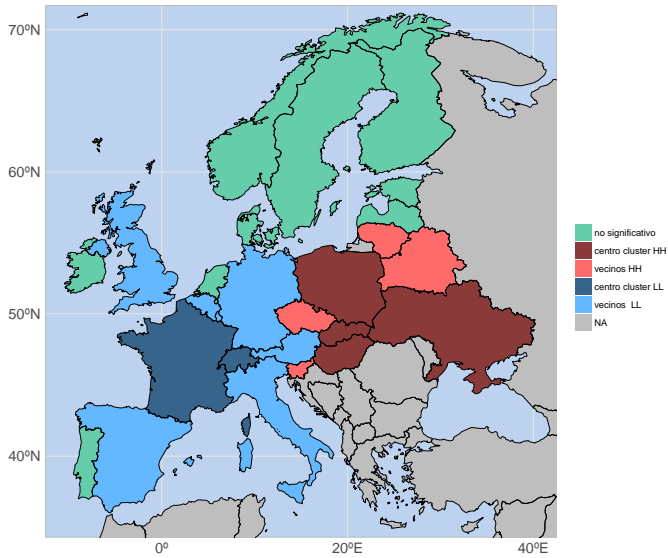
**Figura E.2** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1990.



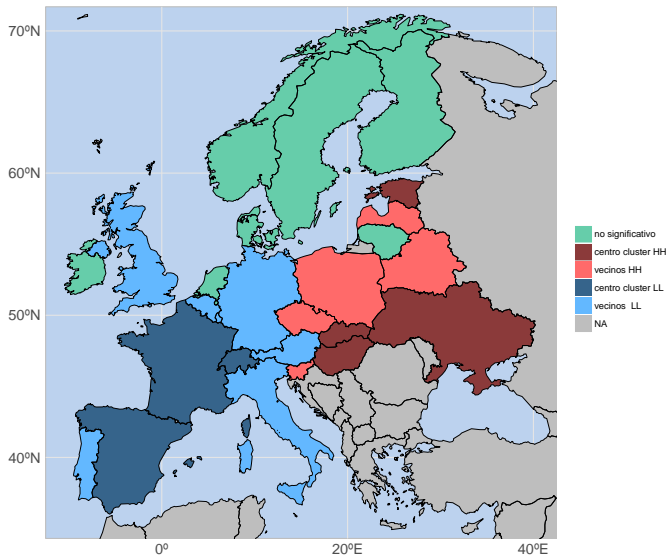
**Figura E.3** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1991.



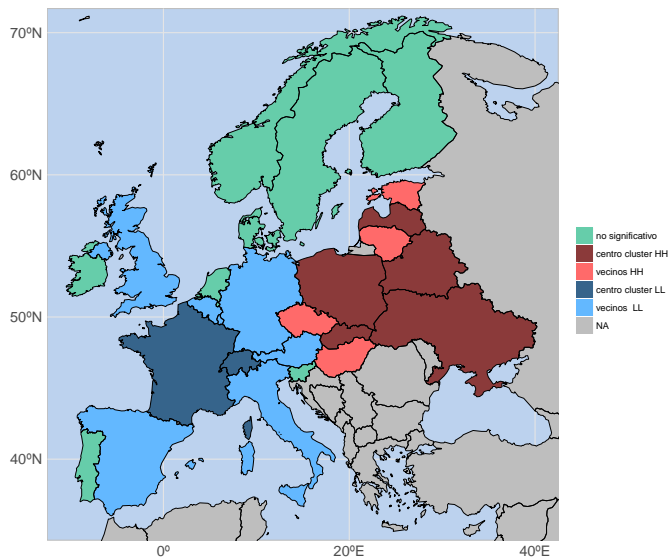
**Figura E.4** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1991.



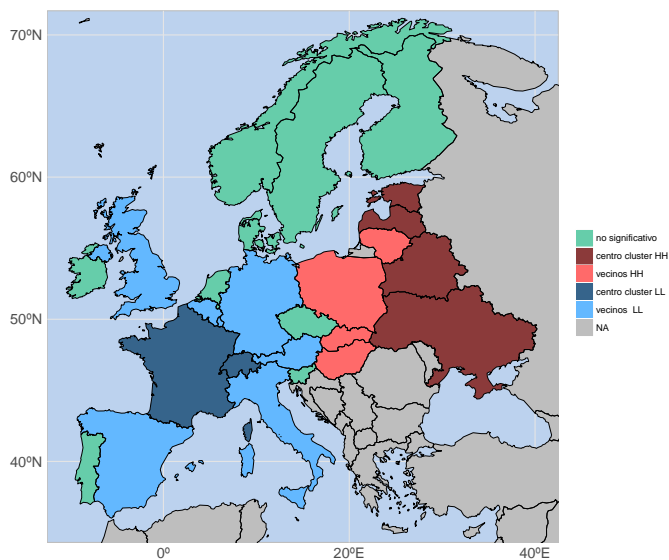
**Figura E.5** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1992.



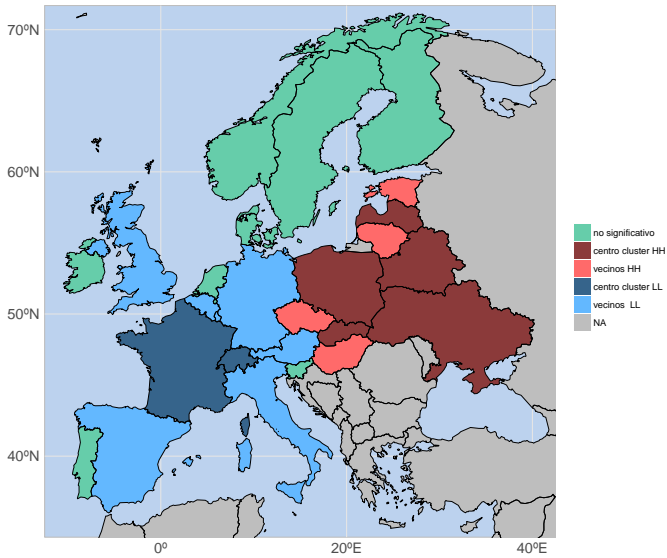
**Figura E.6** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1992.



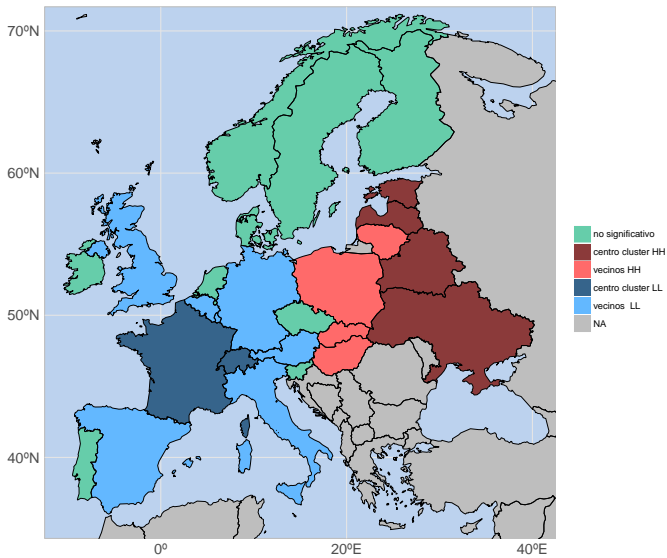
**Figura E.7** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1993.



**Figura E.8** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1993.

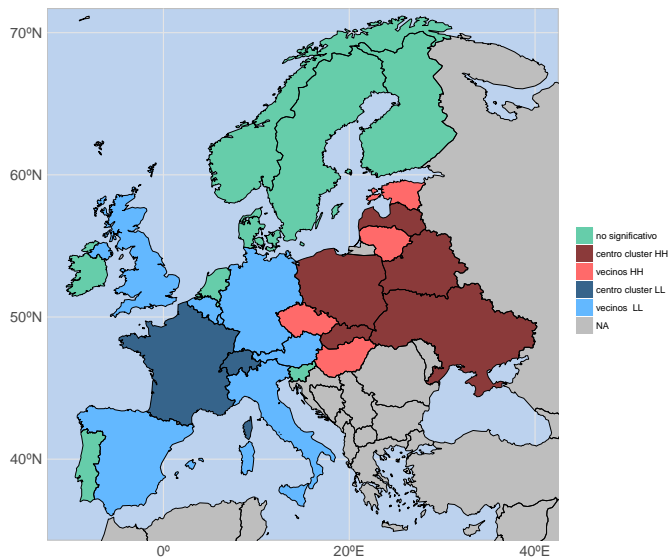


**Figura E.9** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1994.




**Figura E.10** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1994.

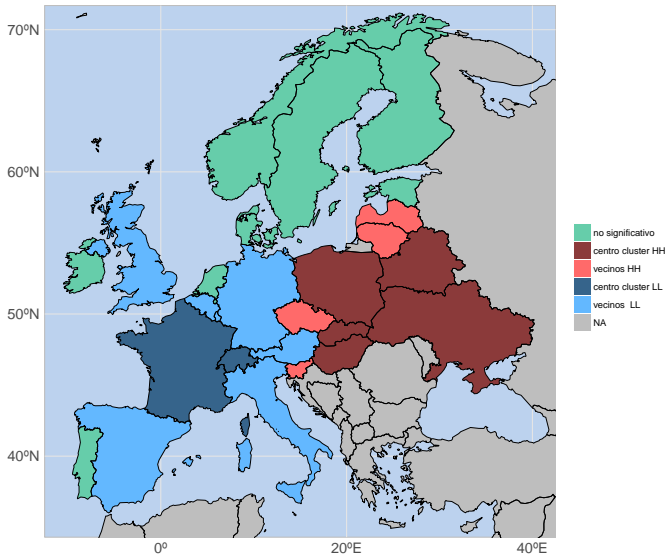




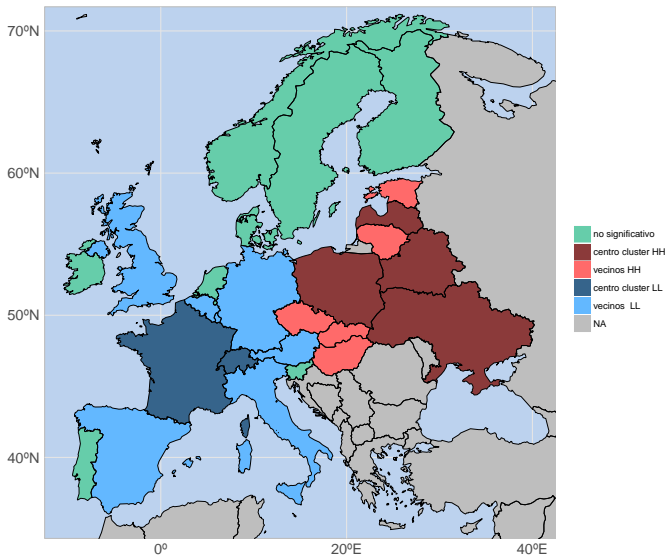
**Figura E.11** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1995.



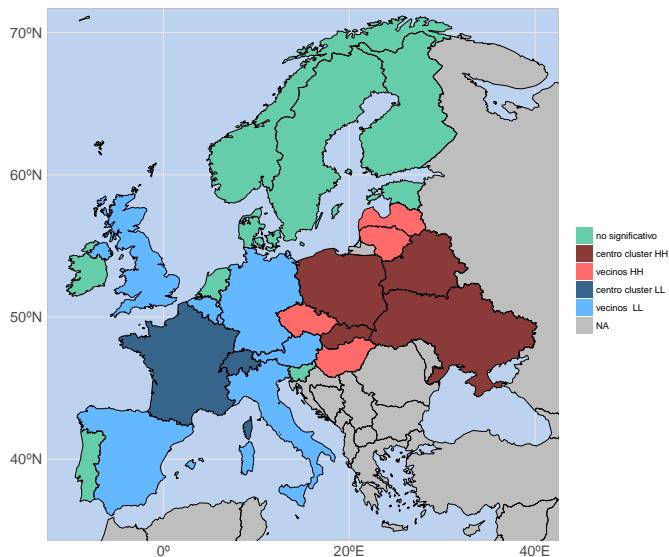
**Figura E.12** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1995.



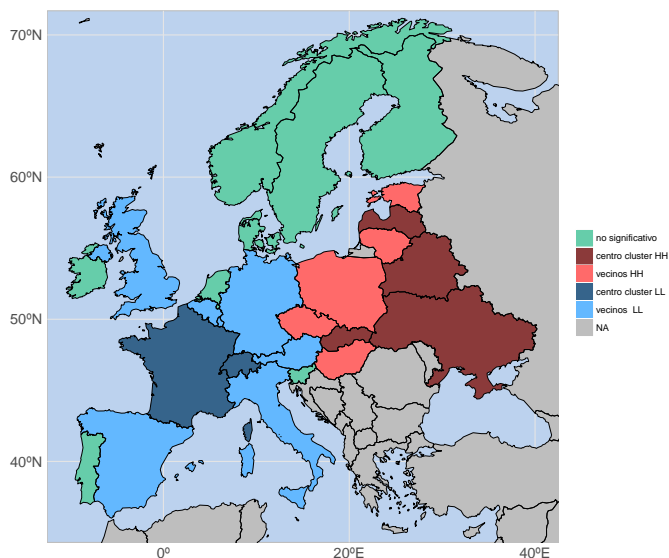
**Figura E.13** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1996.



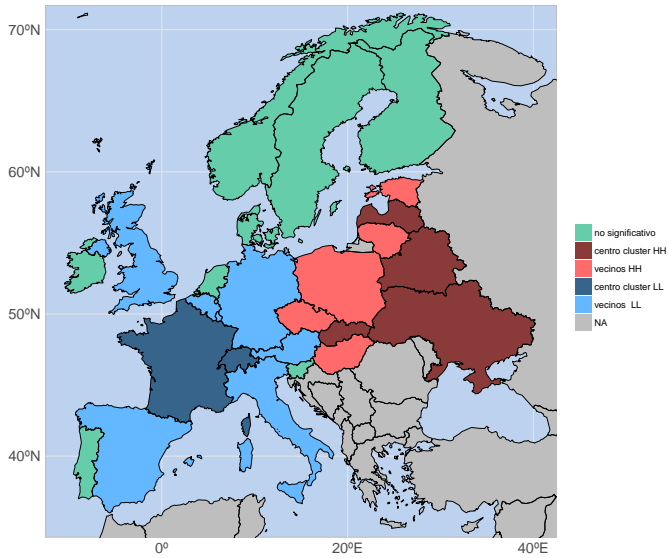
**Figura E.14** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1996.




**Figura E.15** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1997.



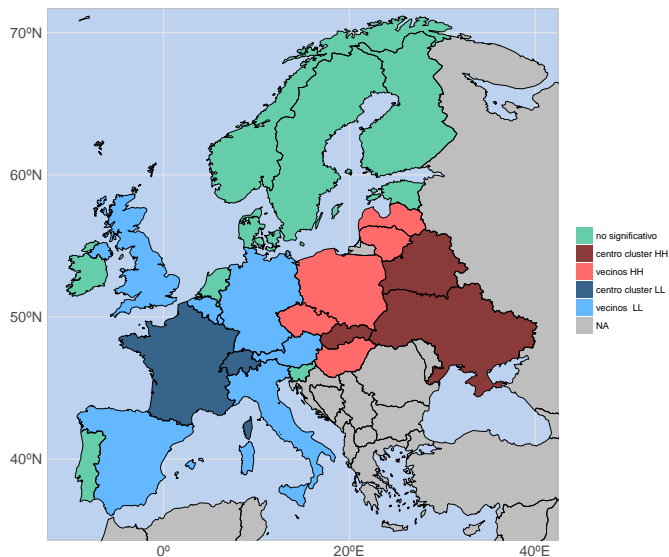
**Figura E.16** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1997.



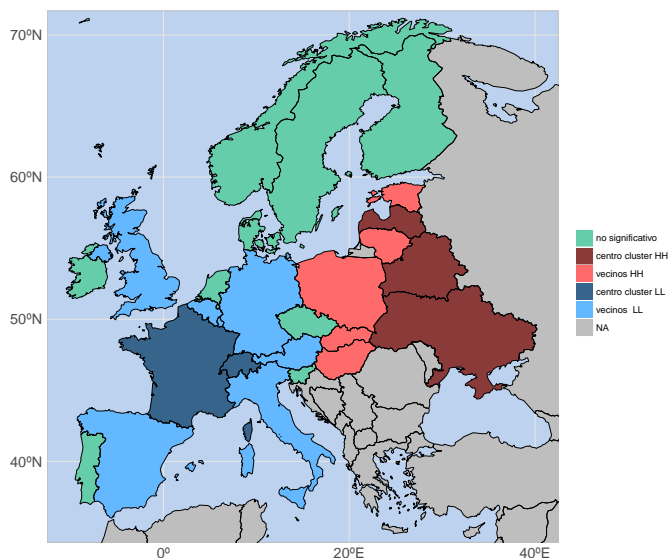
**Figura E.17** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1998.



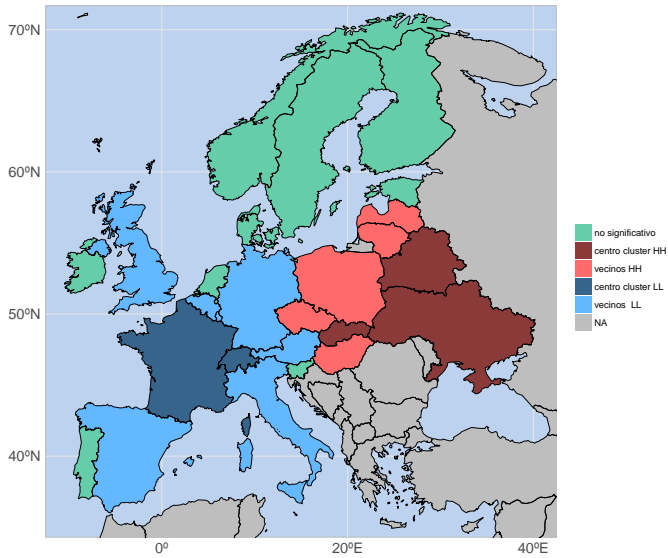
**Figura E.18** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1998.



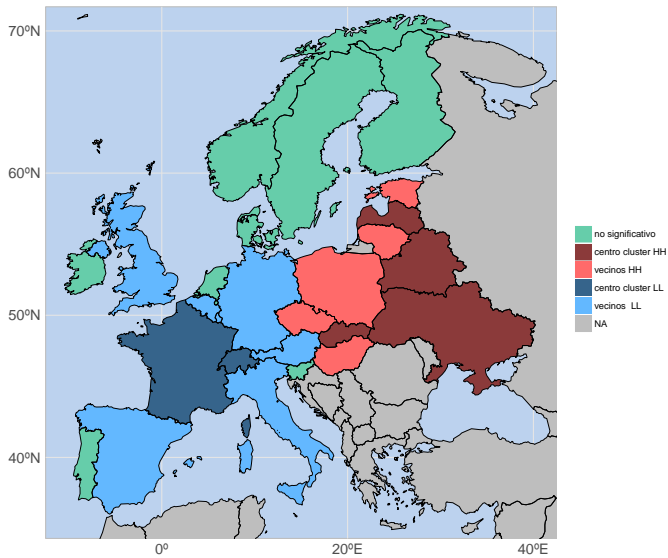
**Figura E.19** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 1999.



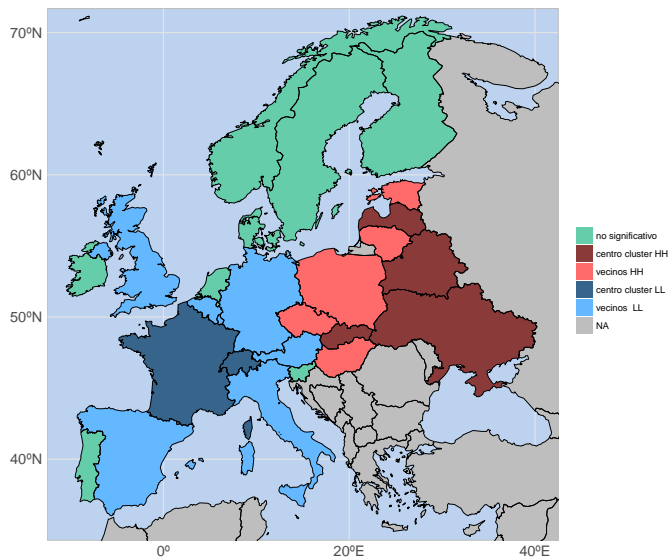
**Figura E.20** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 1999.




**Figura E.21** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2000.



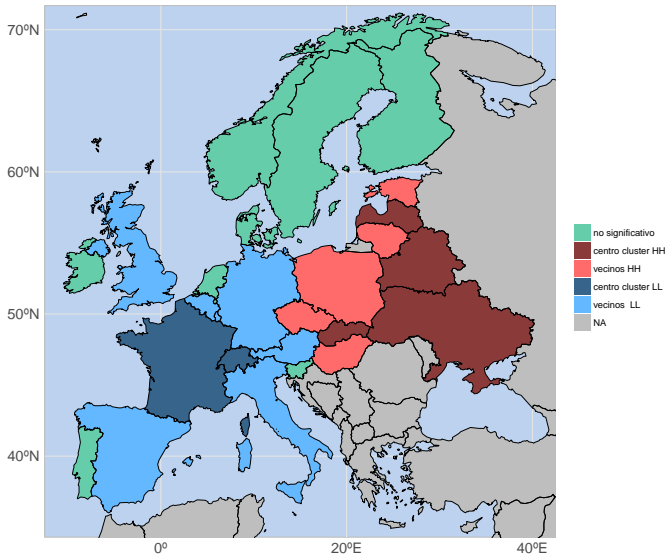
**Figura E.22** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2000.




**Figura E.23** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2001.



**Figura E.24** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2001.




**Figura E.25** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2002.




**Figura E.26** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2002.

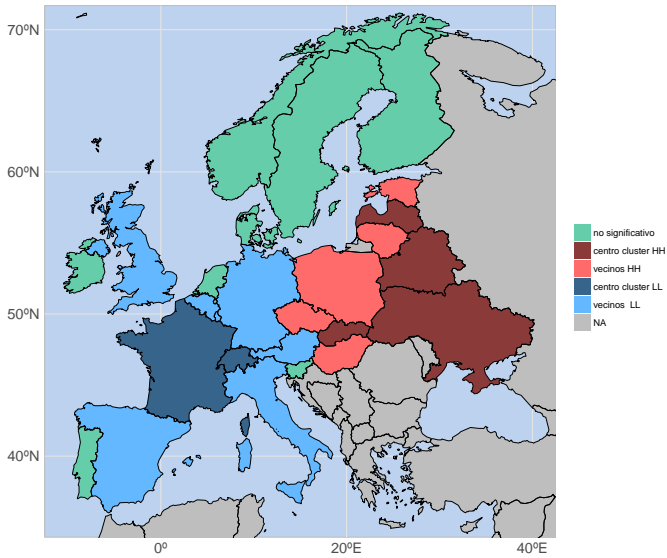




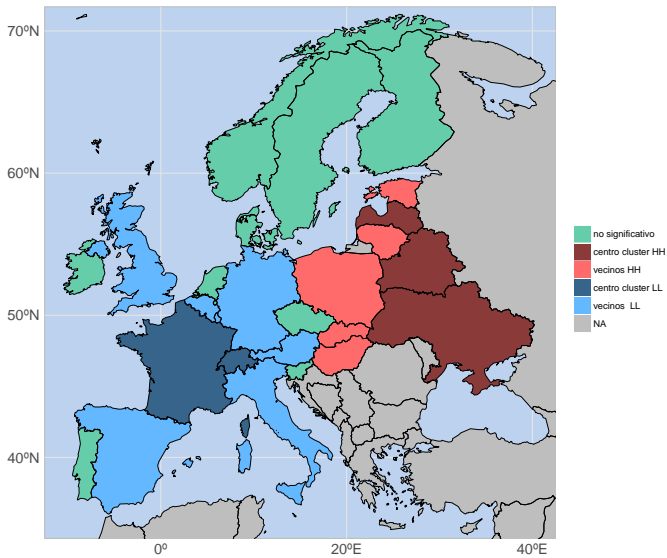
**Figura E.27** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2003.



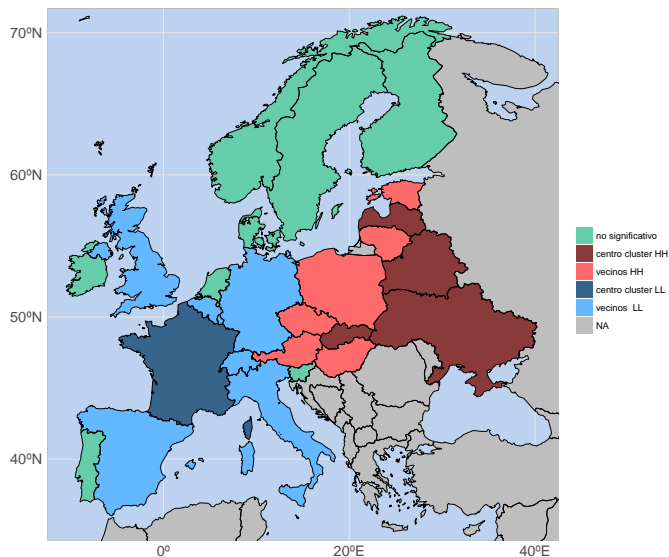
**Figura E.28** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2003.



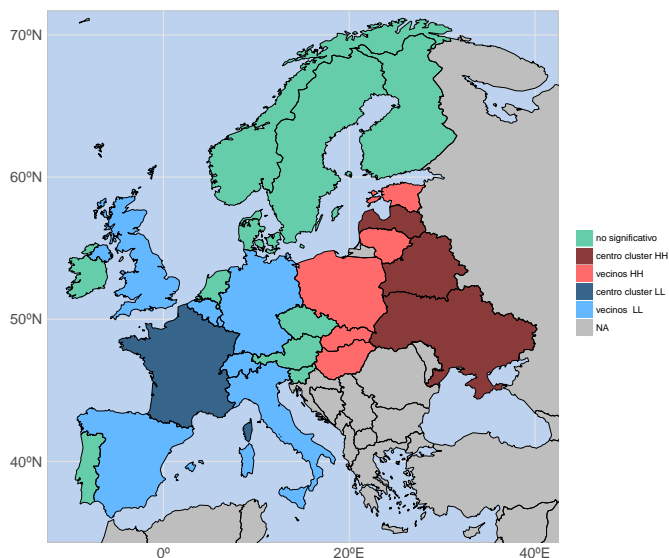
**Figura E.29** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2004.




**Figura E.30** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2004.




**Figura E.31** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2005.




**Figura E.32** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2005.




**Figura E.33** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2006.



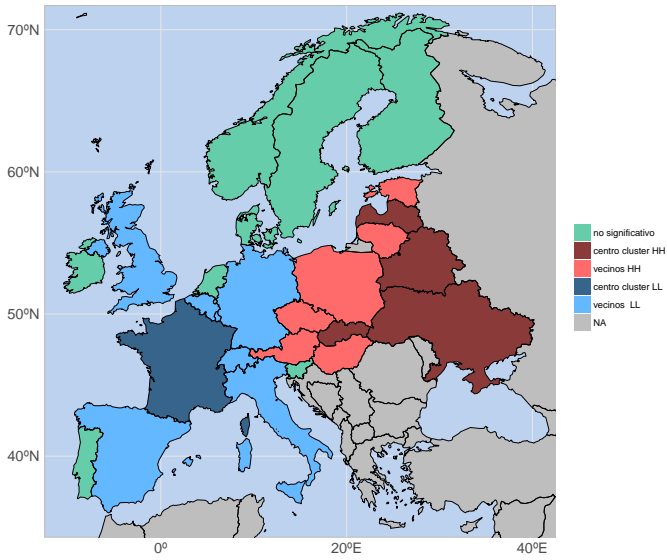
**Figura E.34** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2006.



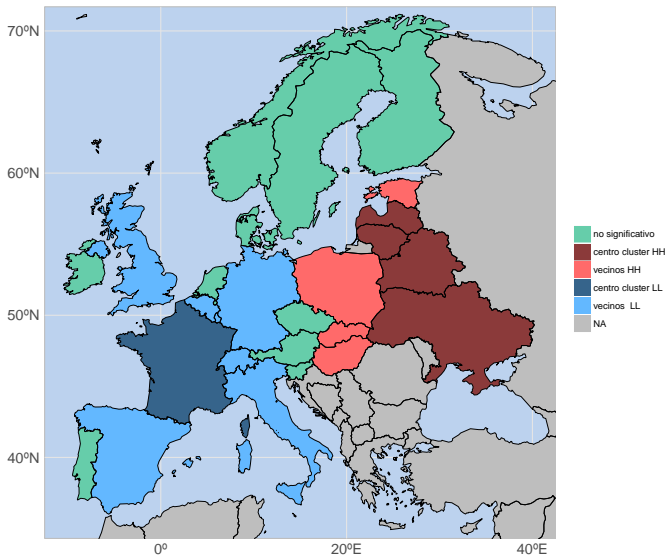
**Figura E.35** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2007.




**Figura E.36** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2007.




**Figura E.37** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2008.



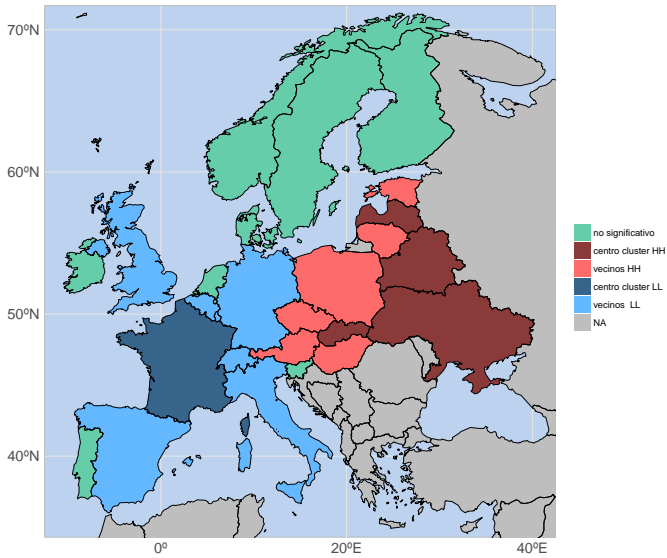
**Figura E.38** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2008.




**Figura E.39** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2009.



**Figura E.40** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2009.

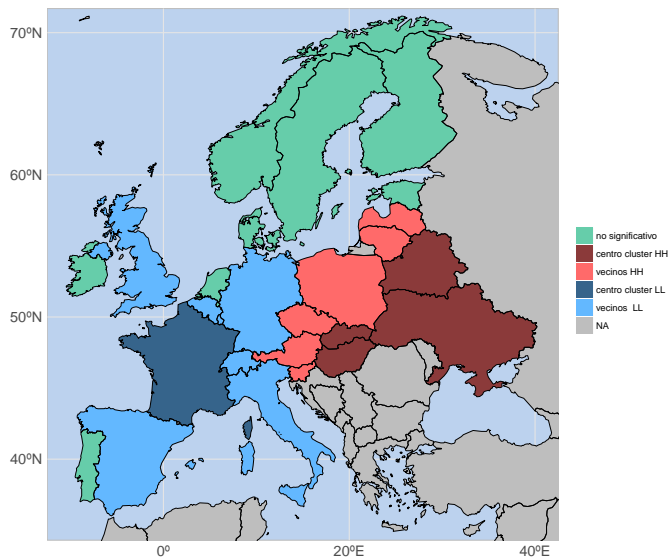


**Figura E.41** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2010.

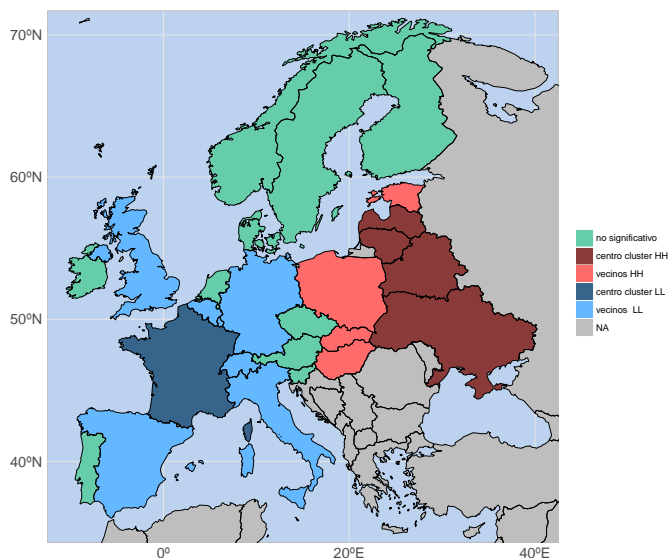


**Figura E.42** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2010.

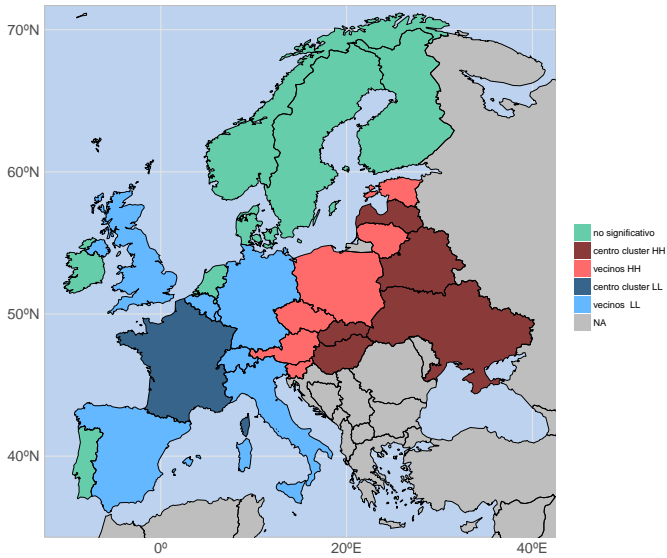





**Figura E.43** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2011.



**Figura E.44** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2011.



**Figura E.45** Mapa de clusters significativos LISA para las mujeres entre 65 y más de 110 años, en el año 2012.



**Figura E.46** Mapa de clusters significativos LISA para los hombres entre 65 y más de 110 años, en el año 2012.