

Grau en Estadística

Títol: Anàlisi de l'esperança de vida en àrees petites a Catalunya

Autor: Marc Arnijas

Directors: Anna Mompert i Xavier Puig

Departament: Estadística i Investigació Operativa

Convocatòria: Q2 2017/2018



RESUM

L'esperança de vida (EV) és un dels indicadors de salut més importants i informatius de la qualitat de vida d'un territori. En territoris amb poca població com són les Àrees Bàsiques de Salut, la metodologia clàssica per a dur a terme el càlcul de l'EV pot tenir limitacions relacionades amb la mida mostral. Aquest fet fa que obtinguem estimadors de l'EV amb una gran variabilitat. Per a controlar aquesta variabilitat crearem diversos models que tinguin en compte l'estructura espacial per tal de suavitzar les estimacions de l'indicador. Representarem les prediccions de l'EV dels diferents models per a cada Àrea Bàsica de Salut (ABS) amb mapes per tal de veure quines ABS de Catalunya tenen valors alts i baixos d'EV per a localitzar on hi ha problemes amb la Salut catalana i poder intervenir-hi.

ABSTRACT

Life expectancy is one of the most important and informative health indicators of the quality of life of a territory. In territories with little population such as the Basic Health Areas (ABS), the classical methodology to carry out the calculation of life expectancy can have limitations related to the sample size. This fact makes us obtain estimators of life expectancy with a great variability. To control this variability, we will create several models that consider the spatial structure to smooth the estimates of the indicator. We will represent the life expectancy predictions of the different models for each Basic Health Area (ABS) with maps to see which ABS of Catalonia have high and low life expectancy values in order to locate where there are problems with the Catalan Health and to intervene there.

PARAULES CLAU

Mortalitat, Esperança de vida, Dades Espacials, Estadística Bayesiana, Representació amb Mapes, Epidemiologia.

CLASSIFICACIÓ AMS

91B72 Spatial models, 62F15 Bayesian inference, 62J12 Generalized linear models.

ÍNDEX

1. INTRODUCCIÓ.....	4
1.1 Motivació	4
1.2 Objectius	4
1.3 Descripció i estructura del projecte.....	4
1.4 Agraïments.....	5
2. DESCRIPCIÓ DE LES BASES DE DADES.....	6
2.1 Mapa de Catalunya per Àrees Bàsiques de Salut (ABS).....	6
2.2 Defuncions	8
2.3 Poblacions.....	10
2.4 Índex de privació.....	12
3. ESPERANÇA DE VIDA (EV).....	16
3.1 Què és l'Esperança de Vida.....	16
3.2 Càlcul de l'Esperança de vida.....	16
3.3 Resultats per ABS.....	18
3.4 Importància del model suavitzat	24
4. DESCRIPCIÓ I RESULTATS DELS MODELS.....	25
4.1 Model 1: Homogeni	26
4.2 Model 2: Índex de privació com a predictor lineal	29
4.3 Model 3: Estructura espacial com a predictor lineal.....	35
4.4 Model 4: Estructura espacial i índex de privació com a predictor lineal.....	41
4.5 Implementació Models.....	47
5. SELECCIÓ I VALIDACIÓ MODELS.....	49
5.1 Selecció del model	49
5.2 Validació dels models	50
6. CONCLUSIONS	57
Bibliografia.....	58
Apèndix 1: Mapes amb etiqueta ABS.....	59
Apèndix 2: Taula sencera que relaciona el codi ABS amb el seu nom	63
Apèndix 3: Taula de districtes	69
Apèndix 4: Funció per calcular l'EV amb codi R	70
Apèndix 5: Codi Models WINBUGS	70
Apèndix 6: Codi R complet	73

1. INTRODUCCIÓ

L'esperança de vida (EV) és un dels indicadors de salut més importants i informatius de la qualitat de vida d'un territori. La creació de mapes amb indicadors de salut ha demostrat tenir una gran utilitat per identificar la ubicació geogràfica dels problemes de salut, identificar desigualtats i realitzar planificacions i intervencions en salut pública. En el nostre treball calcularem aquest indicador per a totes les Àrees Bàsiques de Salut (ABS).

Una Àrea Bàsica de Salut (ABS) és el territori geogràfic, amb la seva població, que és atès per un Equip d'Atenció Primària. Aquesta població sol ser de 5.000 a 25.000 persones. Depenent de la mida de l'ABS, dels nuclis de població i de la dispersió d'aquesta, les ABS poden disposar d'un Centre d'Atenció Primària (CAP), o d'aquest i d'un o més consultoris dependents orgànicament del CAP.

1.1 Motivació

La meua motivació per a dur a terme aquest treball és formar part de un projecte amb dades reals i que pugui servir per a millorar la vida de les persones, com són tots els projectes que estan relacionats amb el camp de la Salut. El fet que el codi R que he creat per a fer el meu treball sigui reutilitzat per el Departament de Salut de la Generalitat de Catalunya per a futurs anàlisis, ha estat un punt a favor per a afrontar la realització del projecte amb moltes ganes.

1.2 Objectius

Els objectius del nostre treball són:

- Calcular l'esperança de vida al néixer amb dades del Registre de Mortalitat de Catalunya dels anys 2011-2015 per a totes les Àrees Bàsiques de Salut, usant la metodologia estadística adequada.
- Crear una funció per a automatitzar el càlcul de l'esperança de vida (EV) per a cada Àrea Bàsica de Salut (ABS), de manera que es pugui reutilitzar aquesta funció per a futurs estudis.
- Implementar un model suavitzat que pugui predir l'EV per a cada ABS, i que aquesta predicció no es vegi afectada per a la gran variabilitat que tenen les àrees amb poca població, com són algunes de les ABS del nostre estudi.

1.3 Descripció i estructura del projecte

La memòria del treball està estructurada en sis capítols. El primer capítol és una introducció del treball realitzat, on explicarem la nostra motivació per a dur a terme el treball, exposarem els nostres objectius i finalment presentarem els capítols amb què està estructurat, amb una petita descripció de cadascun d'aquests capítols.

Al segon capítol es realitza una explicació dels diferents objectes utilitzats, que en el nostre cas són tres bases de dades (defuncions, poblacions i un índex de privació) i un mapa de Catalunya per ABS. Tots aquests objectes donen informació per a cada ABS. A part fem una breu descriptiva d'aquests objectes.

Al tercer capítol es defineix què és l'esperança de vida, i es realitza el càlcul de l'EV per a cada ABS separant per sexe, aquest càlcul el representem amb mapes i recalquem la importància d'un model de suavitzat per a obtenir estimadors amb menys variabilitat i per tant més fiables.

Al quart capítol es presenten els 4 models que hem utilitzat per a predir l'esperança de vida, s'expliquen aquests models i es representen les prediccions amb mapes i finalment s'analitzen aquestes prediccions.

Al cinquè capítol hi trobem la selecció del millor model per a dur a terme prediccions i validem tots els models. Finalment al sisè capítol hi trobem les conclusions del nostre treball.

A continuació, després de les conclusions hi trobem la bibliografia i els annexos amb el codi utilitzat per a la realització del treball i diferents gràfics i taules.

1.4 Agraïments

Als meus tutors de TFG Xavi Puig i Anna Mompert per a tota la seva ajuda i dedicació durant tot el treball.

Als professionals del Servei de Gestió i Anàlisi de la Informació per a la Planificació Estratègica i de la Sub-direcció General de la Cartera de Serveis i el Mapa Sanitari del Departament de Salut pel seu suport. En concret a l'Anna Puigdefàbregas, l'Adriana Freitas, la Glòria Ribas, l'Anna Schiaffino i el Xevi Rosean.

2. DESCRIPCIÓ DE LES BASES DE DADES

En aquest capítol explicarem les diferents bases de dades utilitzades. Presentarem els 4 objectes, que farem servir per a tot el nostre projecte, que ens han facilitat des del Departament de Salut de la Generalitat de Catalunya . Tenim 3 bases de dades i 1 mapa de tot Catalunya per ABS.

Les 3 bases de dades són: 1) Defuncions , 2) Poblacions i 3) L'índex de privació. Les dues primeres són les fonts d'informació per excel·lència en una anàlisi de la mortalitat. Tant les defuncions com la població les agregarem mitjançant el sexe, els grups d'edat i l'Àrea Bàsica de Salut (ABS) de residència. Aquestes bases de dades agrupen la informació dels anys que van des del 2011 al 2015. Per últim tenim un índex de privació per a gairebé quasi cada ABS que és un indicador que reflecteix les diferències socioeconòmiques entre els territoris, quan més baix és aquest indicador més nivell socioeconòmic té aquesta ABS.

2.1 Mapa de Catalunya per Àrees Bàsiques de Salut (ABS)

Abans de parlar de les diferents bases de dades que tenim analitzarem el mapa que és un objecte que tractem molt menys que les bases de dades en la carrera d'estadística però que en aquest treball hem descobert que són molt útils i molt més fàcils de treballar amb ells del que esperàvem. A partir del mapa en format *.shp*, l'hem importat al R amb la funció *readShapePoly* del paquet *maptools*. Aquest mapa ja tenia marcades les fronteres de les diferents ABS. Buscant per la informació que contenia hem pogut marcar al mapa l'identificador que correspon a cada ABS i hem pogut obtenir informació que ens creui l'identificador amb el nom de l'ABS com veurem posteriorment. Aquesta informació ens servirà per identificar quina ABS és cadascuna i ubicar-les al mapa.

Per a cada representació que fem amb mapes, crearem dues figures: una de tot Catalunya i una d'específica de l'Àrea Metropolitana de Barcelona, per a poder veure amb claredat totes les zones del territori. A la Figura 2.1 podem veure quina és cada ABS i on està situada, i a la Figura 2.2 es poden veure les ABS a l'àrea Metropolitana de Barcelona. Tot i això a l'Apèndix 1 es presenten més mapes amb els codis ABS, per zones per tal de facilitar-ne la localització.

Figura 2.1 Mapa Catalunya per ABS





Figura 2.2 Mapa de l'Àrea Metropolitana per ABS



A part de representar els identificadors de l'ABS al mapa, per saber quin territori és cada número hem creat una taula amb l'identificador de l'ABS i el territori que representa. A la taula 2.1 es presenta una part petita de la taula, la taula completa està a l'apèndix 2:

ABS	NOMABS	
1	1	Agramunt
2	2	Alcarràs
3	3	Alfarràs - Almenar
4	4	Amposta
5	5	Anglès
6	7	Aran
7	8	Arbúcies - Sant Hilari
8	9	Arenys de Mar
9	10	Argentona
10	11	Artés
...		
365	390	Sant Cugat del Vallès - 3
366	391	Palau-solità i Plegamans
367	392	Polinyà - Sentmenat
368	393	Ribes - Olivella
369	394	Roquetes - Canyelles
370	395	Barcelona - 9H
371	396	Barcelona - 9I
372	397	Vilafranca del Penedès - 1
373	398	Vilafranca del Penedès - 2
374	399	Castellbisbal
375	400	Barcelona - 3I
376	401	Viladecans - 3

Taula 2.1 Part de la taula que relaciona el codi de l'ABS amb el seu nom.

2.2 Defuncions


A la base de dades de defuncions tenim com a individus les 306725 morts que es van produir entre els anys 2011 i 2015, ja que ens han facilitat aquesta base de dades totalment desagregada. A l'agregar aquestes dades, tenim per a cada ABS el nombre de defuncions, en funció del grup d'edat i sexe, ocorregudes durant el període 2011-2015. A la taula 2.2 veiem part de la base de dades de defuncions. Pel nostre projecte hem fet servir les variables, sexe, grup edat i codi ABS.

	sexe	abs	grupedat	nombredefuncions
1	6	1	1	0
2	6	2	1	1
3	6	3	1	1
4	6	4	1	1
5	6	5	1	0
6	6	7	1	1

Taula 2.2 Part de la base de dades de defuncions

Tot i agregar les defuncions de 5 anys en algunes ABS el nombre de defuncions és molt petit, aquest és un dels grans problemes de calcular indicadors per a àrees petites ja que al tenir pocs efectius els estimadors són molt poc robustos. D'aquí la importància de fer models que suavitzin els resultats com veurem al capítol 4.


Figura 2.3 Nombre defuncions dones per cada ABS (2011-2015)



A la Figura 2.3 es presenta la distribució de les defuncions de dones per ABS. En el cas de les dones, les ABS amb menys de 100 defuncions són l' ABS de Constantí (107), la de Cornudella de Montsant (112), La Granadella (129), Alta Ribagorça (180), Vandellòs i l'Hospitalet de l'Infant (324) i Begues (373). Aquests són els casos més extrems en quant a poques defuncions però també n'hi han uns

quants que tenen un quantitat de defuncions força petita. En canvi tenim ABS on el nombre de defuncions és gran com són Barcelona 2G (27) i Lleida 7 Onze de Setembre (379).

Figura 2.4 Nombre defuncions homes per cada ABS (2011-2015)



A la Figura 2.4 es presenta la distribució de les defuncions de homes per ABS. En el cas dels homes ABS amb menys de 100 defuncions són la ABS de Cornudella de Montsant (112), Alta Ribagorça (180), Begues (373) . La ABS La Granadella (129) té 102 defuncions per a acabar dir les ABS amb molt poques defuncions. En canvi tenim ABS on el nombre de defuncions és gran com Lleida 7 Onze de Setembre (379).

2.3 Poblacions

La base de dades de poblacions a diferència de la de defuncions, la tenim agregada per grup d'edat i ABS i sexe per al període del 2011 al 2015, per aquest motiu només constava de 15540 individus que són els diferents 21 grups d'edat per els dos sexes de les 370 ABS que tenim dades .


A la taula 2.3 veiem un exemple de l'estructura que té la base de dades,

```
> head(poblacio)
  abs sexe grupedat etiagrupedat nombrepoblacio
1   1   1     1      <1           150
2   1   1     2      1-4          761
3   1   1     3      5-9          923
4   1   1     4     10-14         877
5   1   1     5     15-19         901
6   1   1     6     20-24         833
```

Taula 2.3 Part de la base de dades de defuncions

De la mateixa manera que hem fet amb les defuncions agregarem les poblacions per ABS per veure quines ABS consten de poca població. A les figures 2.5 i 2.6 es presenten els histogrammes tant per homes com per dones.


Figura 2.5 Nombre població dones per cada ABS (2011-2015)



En el cas de les dones tenim ABS amb una població força petita, més petita de 10000 habitants.

Com per exemple són Santa Coloma de Queralt (228), Ponts (181), Alta Ribagorça (180), La Granadella (129) i Cornudella de Montsant (112) . En canvi les ABS amb gran població són Terrassa E (251) i Lleida 7 Onze de Setembre (379).

Figura 2.6 Nombre població homes per cada ABS (2011-2015)



En el cas dels homes les ABS més petites, menys de 10000 habitants, són Santa Coloma de Queralt (228) , Ponts (181) , Alta Ribagorça(180) , La Granadella (129) i Cornudella de Montsant(112). En canvi les ABS amb gran població són Terrassa E (251) i Lleida 7 Onze de Setembre (379). Pels dos sexes veiem el mateix fenomen.


Aquestes ABS amb poques defuncions i poca població fan que les taxes de mortalitat per grups d'edat puguin canviar molt a la mínima que canviïn el nombre de defuncions. Per això podem concloure que els indicadors que ens donaran seran molt variables. Per aquest motiu com veurem després hem fet models per tractar de suavitzar l'indicador de l'esperança de vida.

2.4 Índex de privació

Per últim tenim la variable índex de privació per a cada ABS que és un indicador que reflecteix les diferències socioeconòmiques entre els territoris (Àrees Bàsiques de Salut), per tal de reforçar l'equitat territorial en l'assignació dels recursos de l'atenció primària. Aquest índex de privació ha estat construït per l'AQuAS (Agència de Qualitat i Avaluació Sanitàries de Catalunya).

L'índex de privació s'interpreta de la següent manera: valors més elevats de l'índex de privació suposen nivells socioeconòmics més baixos de l'ABS que representa.

Figura 2.7 Índex de privació per ABS



Aquí veiem la distribució que té l'índex de privació en les diferents ABS, en algunes ABS aquest índex no s'ha pogut calcular i tampoc el tenim per les ABS de nova creació, per a dur a terme els models i incloure aquesta variable aquests valors mancants seran imputats.

Per últim, a les figures 2.8 i 2.9 es representa l'índex de privació al mapa, per a veure com està distribuït arreu de Catalunya.

Figura 2.8 Índex de privació per ABS

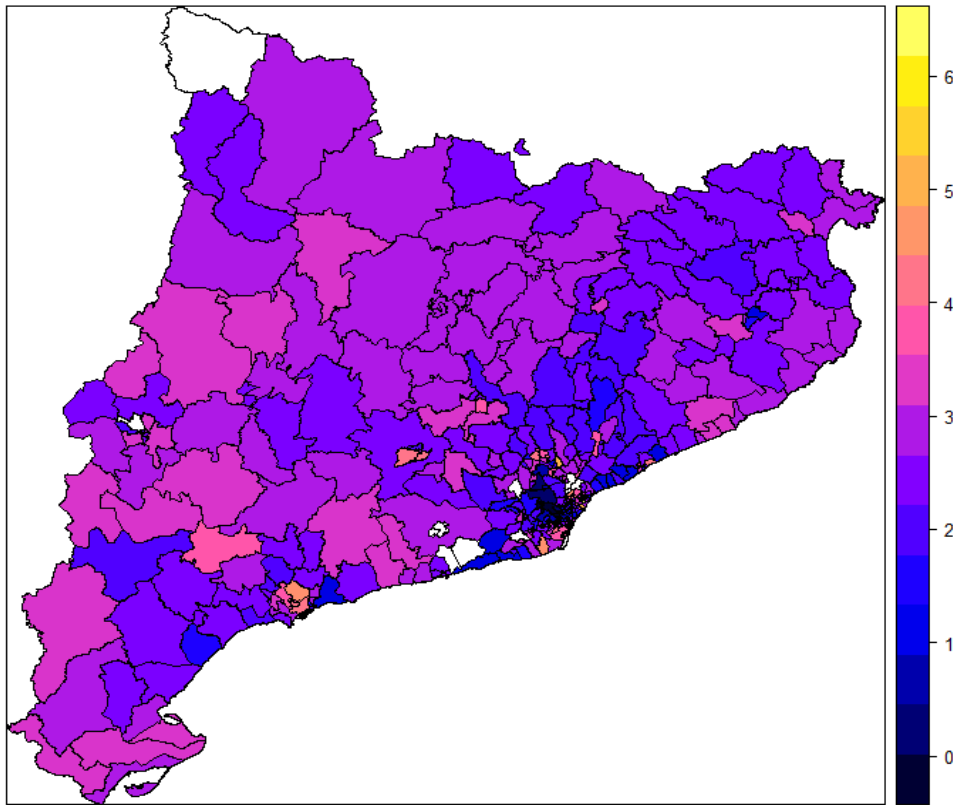
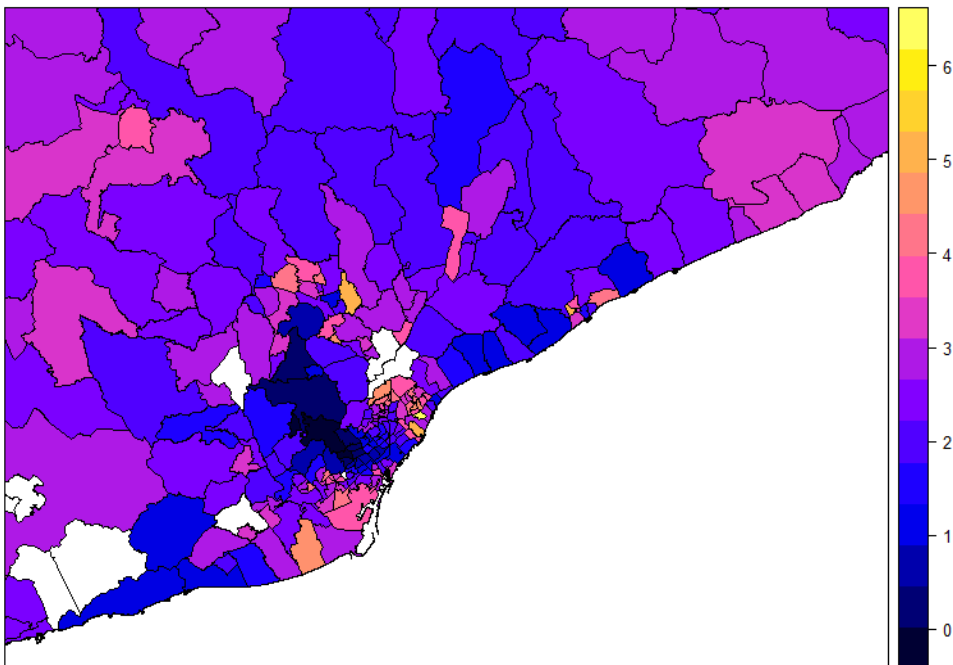


Figura 2.9 Índex de privació per ABS a l'àrea Metropolitana



A la Figura 2.8 els valors d'índex de privació baix, nivell socioeconòmic alt estan a l'àrea metropolitana. A simple vista es pot veure que Constantí (107) té un índex de privació molt alt. Anem a fer zoom al mapa (Figura 2.9) per a analitzar l'àrea metropolitana que és on creiem que veurem més diferències.

A nivell metropolità podem veure diferències d'índex de privació, així l'ABS 276 té el valor més alt de tots els índexs de privació, més de 6, aquest territori és Badalona 5. També tenim valors alts a les ABS 198 que pertany a Sabadell, ABS 157 que pertany a Mataró i a l'ABS 312 que pertany a Sant Adrià del Besos.

En quant a ABS amb valors baixos d'índex de privació, ABS de alt nivell socioeconòmic, trobem les ABS 44 i 45 que pertanyen al districte de Sarrià-Sant Gervasi. A part d'aquestes també tenim altres valors baixos a les ABS 389 i 390 que pertanyen a Sant Cugat del Vallès, la ABS 40 que pertany al districte de Les Corts i les ABS 42,43 i 46 que pertanyen al districte de Sarrià-Sant Gervasi.

Per a saber quina ABS pertany a cada districte utilitzem els noms de les ABS, Apèndix 2, i la taula de districtes, Apèndix 3. El número de després de Barcelona de la taula de l'ABS significa el districte a on pertany l'ABS.

3. ESPERANÇA DE VIDA (EV)

En aquest capítol parlarem de la definició de l'esperança de vida, és a dir què és l'esperança de vida, ja que creiem que molta gent no sap concretar que significa aquest indicador. Posteriorment explicarem com es calcula aquest indicador (taules de mortalitat), i finalment exposarem com hem calculat l'esperança de vida per a cada ABS i ho representarem en mapes per veure quines són les zones de Catalunya on aquest indicador és més favorable i a quines és més desfavorable per a la població que hi viu. Finalment acabarem parlant sobre els problemes que pot tenir calcular aquest indicador en àrees petites i la importància de fer un model suavitzat.

3.1 Què és l'Esperança de Vida

L'esperança de vida és un indicador demogràfic que ens indica el nombre mitjà d'anys de vida que li queden per viure a una persona en el moment en què s'elabora la taula de mortalitat suposant que les taxes de mortalitat es mantenen constants respecte el moment de creació de la taula. L'esperança de vida més utilitzada és l'esperança de vida al néixer que és la que calcularem en tot el nostre treball.

L'esperança de vida al néixer és el nombre mitjà d'anys que s'espera viuria un nou-nat, si en el transcurs de la seva vida estigués exposat a les mateixes taxes de mortalitat específiques per edat i per sexe en el moment del seu naixement, per a un període específic, en un determinat país, territori o àrea geogràfica. En el nostre cas tractem l'esperança de vida que tenen els individus de 0 anys nascuts entre els anys 2011 i 2015 de les diferents ABS de Catalunya.

3.2 Càlcul de l'Esperança de vida

Mitjançant RStudio hem implementat una funció per a calcular l'esperança de vida de la mateixa manera com es calcula mitjançant les taules de mortalitat. A l'Apèndix 4 es presenta la funció en codi R.

Aquí presentarem com es calcula una taula de mortalitat abreujada, direm que significa cada variable i com es calcula.

Primer de tot necessitem una sèrie d'imputs per a calcular l'EV que són:

d_x = nombre de defuncions a l'interval d'edat x

p_x = població a l'interval d'edat x

n_x = amplada de l'interval d'edat x

a_x = fracció de temps viscut, que representa, de les persones que moren en l'interval d'edat x, la fracció de temps de l'interval que viuen.

Es calcula com a:

$$a_x = \frac{Tdies_x}{(dies - de - l'any) * n_x * d_x}$$

$dies - de - l'any$ = 365 o 366 els anys de traspàs

$Tdies_x$ = suma de tots els dies viscuts a l'interval x, de tots els individus. Cal dir que nosaltres no teniem aquesta informació per a cada ABS.

Llavors el que hem fet és utilitzar la fracció d'anys viscut (a_x) de la població general (Catalunya Dones i Homes) i usar-la per a totes les ABS.

A partir d'aquí la taula de mortalitat s'actualitza automàticament:

m_x = taxa específica de mortalitat en l'interval d'edat x

$$m_x = \frac{d_x}{p_x}$$

q_x = Probabilitat de morir en l'interval d'edat x

$$q_x = \frac{n_x * m_x}{1 + (1 - a_x) * n_x * m_x}$$

$$q_{+95} = 1$$

l_x = Sobrevivents a l'inici de l'interval d'edat x

$$l_0 = 100000$$

$$l_{x+1} = l_x - d_x$$

d_x = Defuncions de la taula de vida en l'interval d'edat x

$$d_x = l_x * q_x$$

L_x = Anys viscuts en l'interval d'edat x

$$L_x = n_x * (l_x - (1 - a_x) * d_x)$$

$$L_{+95} = \frac{l_{+95}}{m_{+95}}$$

T_x = Anys que queden per viure en l'interval d'edat x

$$T_{+95} = L_{+95}$$

$$T_x = L_x + T_{x+1}$$

e_x = Esperança de vida a l'edat x

$$e_x = \frac{T_x}{l_x}$$

e_0 = Esperança de vida al néixer, nombre mitjà d'anys de vida d'una persona.

$$e_0 = \frac{T_0}{l_0}$$

A partir d'aquí hem calculat l'EV per a cada ABS separant per sexe. L'esperança de vida que calculem és l'indicador que fa referència als anys 2011-2015. En aquest període hi ha ABS que al començament hi eren i ara no o viceversa, això fa que hi hagi una manca de dades en alguns anys concrets. Així per a algunes ABS no s'ha pogut calcular l'EV. Els models del capítol 4 ens permetran donar una estimació de l'EV per a aquestes ABS que no s'ha pogut calcular.

3.3 Resultats per ABS

Un cop obtinguts els resultats els representarem de la millor manera possible, mitjançant mapes.

Abans de començar amb els mapes farem un histograma de les esperances de vida de les diferents ABS separant per sexes. A la Figura 3.1 podem veure que la distribució de l'EV per les diferents ABS de les dones té aspecte de normal, centrada en 85 anys. Podem veure que hi ha valors extrems d'esperances de vida de diferents ABS, que arriben a 90 en el millor cas i a 80 en el pitjor.

Figura 3.1 Histograma EV Dones per ABS





Figura 3.2 Histograma EV Homes per ABS



En el cas dels homes, a la Figura 3.2 veiem el mateix comportament que en les dones però traslladat 5 anys menys. La campana està centrada entre 80-81 i el mínim està en 75 anys i el màxim en 84.

Podríem concloure que els individus nascuts entre el 2011 i 2015 en mitjana viuran 5 anys més si són dones. Per a acabar de veure aquest fet anem a superposar els gràfics.

A la Figura 3.3, podem veure el que anunciàvem, són dues distribucions similars però una està centrada 5 anys més amunt que l'altre. Un cop vist com seran els valors de les esperances de vida les representarem amb mapes:

Figura 3.3 Histogrames EV per ABS dels 2 sexes




Figura 3.4 Esperança de vida homes de Catalunya

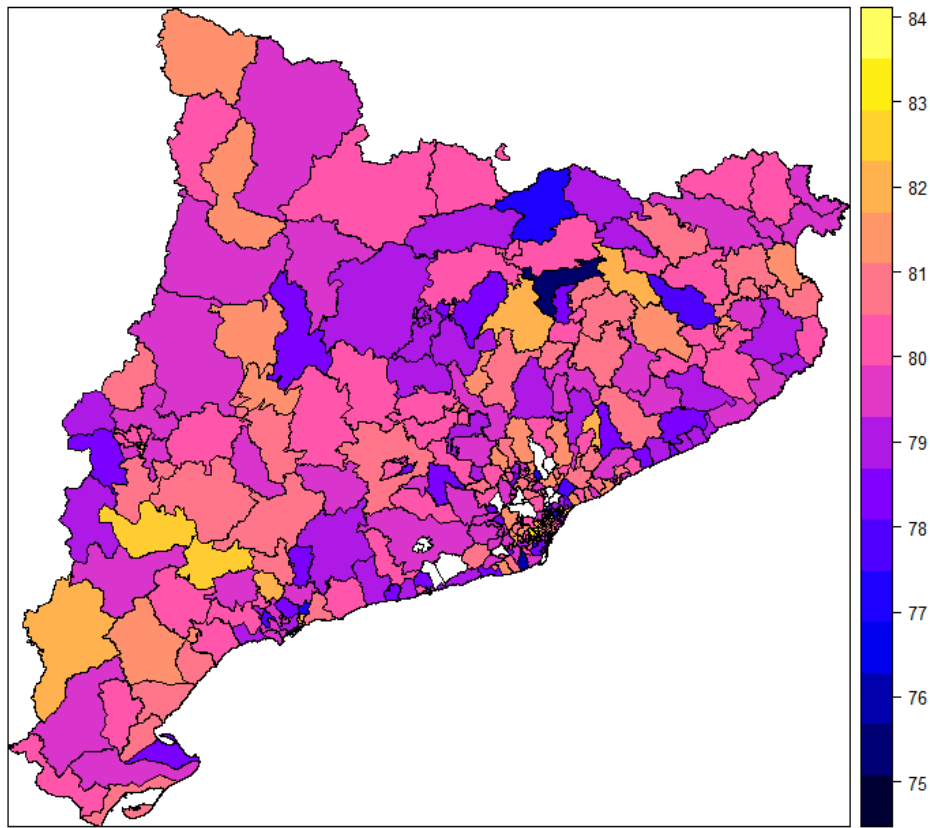



Figura 3.5 Esperança de vida homes de l'Àrea Metropolitana



En el cas de les esperança de vida dels homes, Figura 3.4, podem veure que els valors van dels 75 als 84 anys aproximadament. També s'observa que l'ABS de Sant Quirze de Besora (217) té l'esperança de vida més baixa i que les ABS que tenen l'esperança de vida més alta són les ABS de La Granadella (129) i Cornudella de Montsant (112) respectivament. Com que la zona metropolitana no es pot veure bé farem un zoom, Figura 3.5, per veure quines són les ABS amb comportaments més extrems. Les ABS que veiem de color blanc són ABS on no hi tenim informació o la informació no la tenim en tots els anys, ja que són ABS que en el període d'anàlisi van patir canvis en les divisions territorials, per tant no té sentit mapejar-les.

A nivell metropolità, Figura 3.5, podem veure que l'ABS 40, que pertany al districte de les Corts és la que té l'esperança de vida més alta, aproximadament 84 anys. També tenen valors alts tot i tenir un color més fosc de llegenda les ABS 44 i 41 que estan al costat de l'ABS 40 i pertanyen al districte de Sarrià-Sant Gervasi i les Corts respectivament. També tenen valors alts tot i no ser tan properes a l'ABS 40, les ABS 344 que es troba a Sabadell i l'ABS 277 que es troba a Badalona. Com a contraposició tenim les àrees amb esperances baixes com poden ser les ABS 312, 341 i 16 que pertanyen a Sant Adrià del Besos , Badalona i al districte de Ciutat Vella respectivament. Com a curiositat dir que les ABS 277, que és una de les més altes i 341, que és una de les més baixes, són veïnes i a part formen part de la mateixa ciutat que és Badalona.

En quant a les dones a simple vista, Figura 3.6, podem veure els valors van dels 80 als 90 anys aproximadament. Els dos valors són aproximadament 5 anys més alts que en el cas dels homes. En quant a ABS concretes tornem a veure que l'ABS de La Granadella (129) tant en homes com en dones té una de les esperances de vida més alta del territori català, en el cas de les dones aproximadament de 89 anys.

En quant a l'àrea metropolitana, Figura 3.7, podem veure que l'esperança de vida més alta, 90 anys queda ubicada en l'ABS 70 i és del districte de Sant Andreu, tret d'aquesta, no es veuen més àrees amb valors alts. Respecte a valors baixos, també en veiem només un, l'ABS 341 que pertany Badalona. De mateixa manera que en el cas dels homes aquest és un territori que té esperança de vida molt baixa, en els dos sexes. A contraposició del que passa amb La Granadella(129).

Figura 3.6 Esperança de vida dones de Catalunya

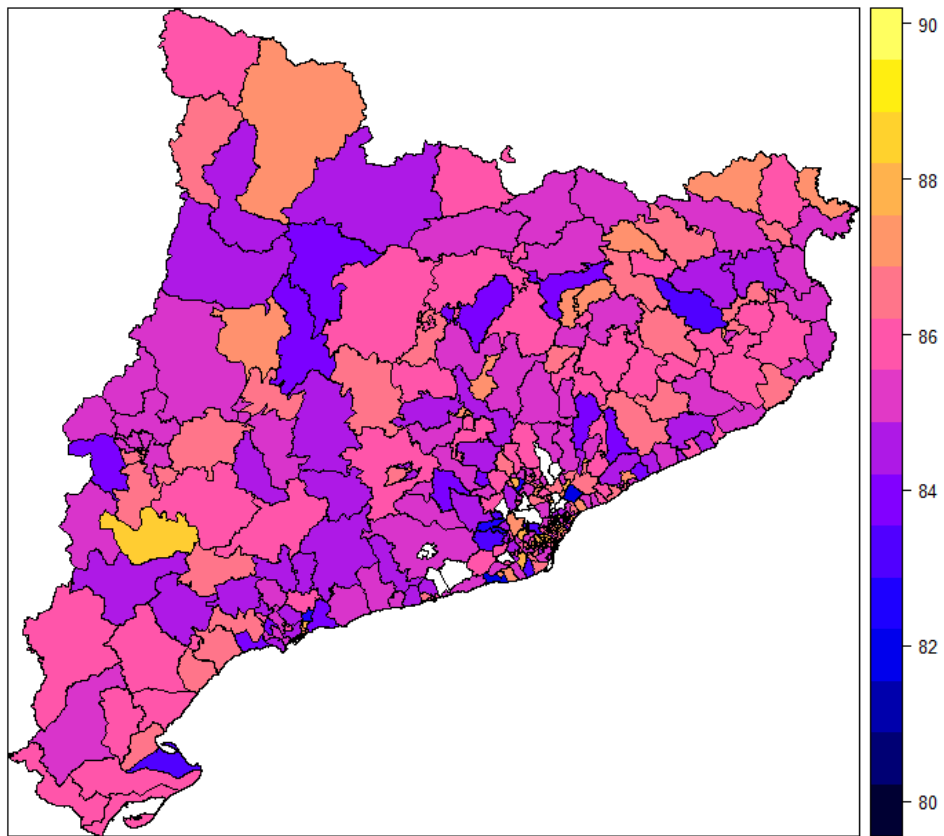
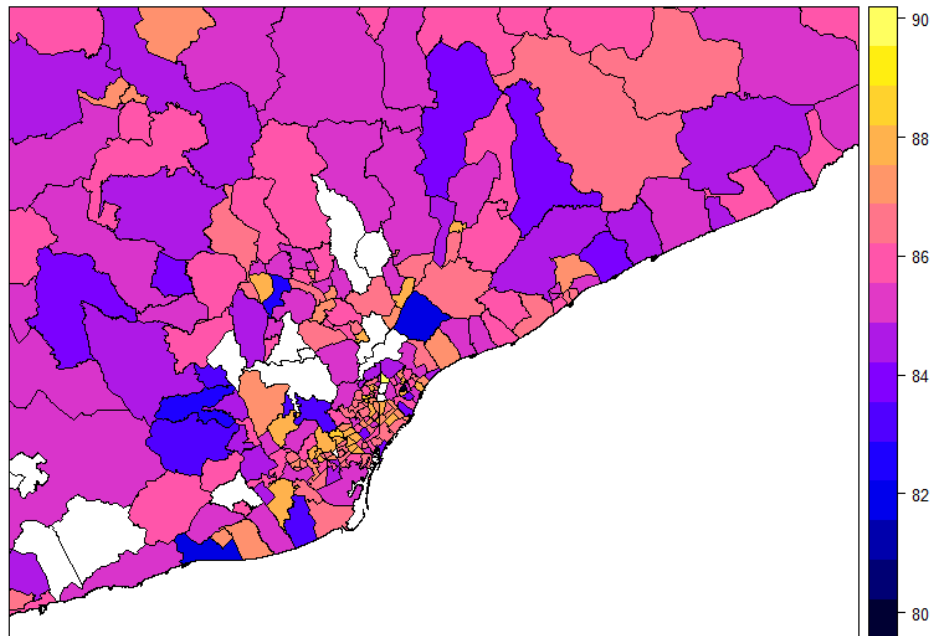


Figura 3.7 Esperança de vida dones de l'Àrea Metropolitana



3.4 Importància del model suavitzat

Amb la descriptiva de les dades de les defuncions i les poblacions hem vist que tenim ABS amb molt poca població i molt poques defuncions. Si pensem que aquesta població i aquestes defuncions s'han de distribuir en els diferents 21 grups d'edat és lògic pensar que tenim uns numeradors i denominadors molt petits i que per mínima que sigui la variació en aquestes dades ens afecta molt a l'indicador que estem calculant, això implica que l'indicador de l'EV per ABS no és gens robust, és a dir, obtenim uns estimadors per ABS amb molta variabilitat. Per exemple 2 de les ABS amb menys població i menys defuncions ens donen 2 dels valors més alts en esperança de vida, aquestes ABS són Cornudella de Montsant (112) i La Granadella (129).

Per a intentar millorar aquests indicadors que trobem poc representatius ja que són estimadors amb una gran variabilitat, el que hem cregut més convenient és fer models per a predir l'esperança de vida que a part de la informació del territori tinguin en compte la informació de les ABS veïnes, ABS que les seves fronteres estan en contacte, de manera que al fer servir les ABS veïnes treballarem amb més població i més defuncions, fet que farà que aquest indicador sigui molt més robust, per tant, serà un estimador que tindrà molta menys variància.

4. DESCRIPCIÓ I RESULTATS DELS MODELS

Com hem acabat d'explicar al capítol anterior, 3.4, per a obtenir un indicador de l'esperança de vida més representatiu de cada ABS necessitaríem tenir mostres més grans per tractar d'obtenir un estimador amb menys variabilitat.

Per a dur a terme estimacions robustes, amb la informació que tenim s'han creat 4 models que posteriorment descriurem. Per a crear-los, ens basarem amb l'estadística Bayesiana. La diferència amb l'estadística freqüentista és que l'estadística Bayesiana fa servir la idea de la distribució a priori que és la distribució que els experts consideren que pot tenir la variable a estudiar. En el nostre cas, farem servir funcions a priori poc informatives, cosa que vol dir que, a la nostra funció a posteriori pesará molt la informació de les dades. Tot i així per als models 3 i 4 utilitzarem una a priori amb estructura espacial que permet tenir en compte que les àrees veïnes s'assemblin.

Aquesta funció a priori s'actualitzarà mitjançant el teorema de Bayes que ens permetrà combinar aquesta informació a priori juntament amb la informació de les dades observades per obtenir la distribució a posteriori. No obstant, per alguns models no és possible calcular la distribució a posteriori de forma tancada, però sí obtenir simulacions d'aquesta utilitzant els algorismes MCMC (Markov chain Monte Carlo).

Aquesta funció a posteriori la farem servir per a obtenir les nostres estimacions puntuals de l'esperança de vida per ABS. A part de donar estimacions puntuals dels paràmetres també donarem estimacions per intervals. En estadística Bayesiana l'interval que es pren és l'interval de credibilitat, generalment abreviat com a IC, però no s'ha de confondre amb l'interval de confiança que és el que usa l'estadística freqüentista. Un interval de credibilitat és una regió on el paràmetre a estudiar, que no coneixem el seu valor real, té una probabilitat de ser-hi de $1-\alpha$. En el nostre cas α serà 0.05. Per tant en els nostres intervals la probabilitat de tenir el valor real del paràmetre, que és desconegut per a nosaltres, en aquesta regió serà del 95%.

Posteriorment els comentarem més detingudament però, els 4 models per a predir l'esperança de vida són els següents:

- Model 1: Homogeni
- Model 2: Índex de privació com a predictor lineal
- Model 3: Estructura espacial com a predictor lineal
- Model 4: Estructura espacial i índex de privació com a predictor lineal

Les prediccions d'aquests models les calcularem mitjançant WINBUGS, un software per la anàlisi de models bayesianes amb un mètode basat amb simulacions de MonteCarlo mitjançant cadenes de

Markov. Aquests mètodes permeten mostrejar la distribució a posteriori, encara que aquesta sigui desconeguda, gràcies a la construcció d'una cadena de Markov. I podem extreure estimacions puntuals i intervals de Credibilitat d'ella. Per últim comentarem els resultats que ens ha donat cada model.

4.1 Model 1: Homogeni

El primer model considera que tots els valors venen de la mateixa distribució que és una Normal. Per tant podem pensar i després comprovarem que tots els valors predits seran iguals. Escrivim el model com:

$$EV_i | \mu, \sigma \sim \text{Normal}(\mu, \sigma).$$


$$\mu \sim \text{Normal}(80, 10)$$

$$\sigma \sim \text{Unif}(0, 10)$$

El model 1 suposa que l'EV es distribueix idènticament per a totes les ABS. Les prioris que hem escollit són poc informatives, la priori de μ suposa que el valor esperat de l'EV està entre 60 i 100, $(80-2*10, 80+2*10)$, amb un 95% de probabilitat. Per a la desviació típica de l'EV hem triat una a priori que dona la mateixa probabilitat a tots els valors de l'interval de 0 a 10.

Si representem les funcions a posteriori veiem el següent:

Figura 4.1 Posterioris Model 1 EVD




En el cas de les dones veiem que la posteriori de la μ està centrada en aproximadament 85.8, i l'interval de credibilitat al 95% de μ és [85.67,85.92]. Això significa que aquesta regió amb un 95% de probabilitat contindrà el paràmetre μ . Per la σ veiem que la posteriori està centrada en aproximadament 1.23, i l'interval de credibilitat al 95% de σ és [1.15,1.33].

	mean	sd	2.5%	25%	50%	75%	97.5%
mu	85.79252	0.064889	85.67000	85.750	85.790	85.840	85.92000
sigma	1.23497	0.046120	1.14700	1.203	1.234	1.264	1.33000

Taula 4.1 Percentils μ i σ Model 1 EVD

Figura 4.2 Posterioris Model 1 EVH



En el cas dels homes veiem que la posteriori de la μ està centrada en aproximadament 80.05, i l'interval de credibilitat al 95% de μ és [79.92,80.18]. Per la σ veiem que la posteriori està centrada en aproximadament 1.28, i l'interval de credibilitat al 95% de σ és [1.19,1.38].

	mean	sd	2.5%	25%	50%	75%	97.5%
mu	80.048019	0.067319	79.92000	80.0000	80.050	80.090	80.18000
sigma	1.282616	0.048234	1.19300	1.2490	1.281	1.314	1.37800

Taula 4.2 Percentils μ i σ Model 1 EVH

Representant els resultats en el mapa veiem el que intuïem:

Figura 4.3 Model 1 Esperança de Vida Dones de Catalunya





Figura 4.4 Model 1 Esperança de Vida Homes de Catalunya



En el cas de les dones, Figura 4.3, per tal com s'ha definit el model veiem, que l'esperança de vida és el valor mitjà de les esperances de vida, 85.79 .

En el cas dels homes, Figura 4.4, el mapa té el mateix comportament però amb un valor d'esperança de vida més baixa, 80.05 .

En aquest cas per tots dos sexes veiem que totes les ABS tenen, la mateixa estimació puntual, que és la mitjana de les esperances de vida.

4.2 Model 2: Índex de privació com a predictor lineal

El segon model a diferència del primer model tindrà valors diferents per cada ABS ja que les prediccions depenen de dos paràmetres, el primer β_0 representa l'esperança de vida d'una ABS que el seu índex de privació és 0 i el segon β_1 és el nombre d'anys que canvia l'esperança de vida quan augmenta una unitat l'índex de privació. El signe esperat d'aquest paràmetre és el signe negatiu, és a dir com més nivell socioeconòmic tingui la esperança de vida, més baix sigui l'índex de privació, més alta serà l'esperança de vida. Escrivim el model com:

$$EV_i | \beta_0, \beta_1, \sigma \sim \text{Normal}(\beta_0 + \beta_1 * IP_i, \sigma)$$

$$\beta_0 \sim \text{Normal}(80, 10)$$


$$\beta_1 \sim \text{Normal}(1, 10)$$

$$\sigma \sim \text{Unif}(0, 10)$$

El model 2 suposa que l'EV està explicada en part per l'índex de privació i utilitzem aquest paràmetre per a millorar-ne les estimacions. Les prioris que hem escollit són poc informatives i suposen, que el valor esperat de l'EV d'una ABS on l'índex de privació sigui 0 estarà entre 60 i 100 amb un 95% de probabilitat i que el valor esperat del coeficient que multiplica l'índex de privació estarà entre -19 i 21 amb un 95% de probabilitat. Respecte a la desviació típica de l'EV hem triat una a priori que dona la mateixa probabilitat a tots els valors de l'interval de 0 a 10.

A la Figura 4.5 i a la Taula 4.3 es mostren les distribucions a posteriori i un resum d'elles, en el cas de les dones veiem que la posteriori de la β_0 (a0 a la taula) està centrada en aproximadament 86.25, i l'interval de credibilitat al 95% de β_0 és [85.85,86.6]. Per la β_1 veiem que està centrada en aproximadament -0.17, i l'interval de credibilitat al 95% de β_1 (a1 a la taula) és [-0.30,-0.03]. Per la σ veiem que la posteriori està centrada en aproximadament 1.23, i l'interval de credibilitat al 95% de σ és [1.14,1.32].

Figura 4.5 Posterioris Model 2 EVD




	mean	sd	2.5%	25%	50%	75%	97.5%
a0	86.229234	0.196104	85.850000	86.1000	86.2300	86.3600	86.610000
a1	-0.167769	0.071111	-0.306203	-0.2164	-0.1684	-0.1197	-0.028329
sigma	1.227174	0.046144	1.141000	1.1950	1.2260	1.2570	1.322000

Taula 4.3 Percentils β_0 , β_1 i σ Model 2 EVD

A la Figura 4.6 i a la Taula 4.1 es mostren les distribucions a posteriori i un resum d'elles, en el cas dels homes veiem que la posteriori de la β_0 (a0 a la taula) està centrada en aproximadament 81.84, i l'interval de credibilitat al 95% de β_0 és [81.5,82.19]. Per la β_1 veiem que està centrada en aproximadament -0.69, i l'interval de credibilitat al 95% de β_1 (a1 a la taula) és [-0.81,-0.56]. Per la σ veiem que la posteriori està centrada en aproximadament 1.11, i l'interval de credibilitat al 95% de σ és [1.03,1.20].

Figura 4.6 Posterioris Model 2 EVH



	mean	sd	2.5%	25%	50%	75%	97.5%
a0	81.840479	0.176327	81.500000	81.7200	81.8400	81.9600	82.190000
a1	-0.690655	0.064390	-0.818505	-0.7342	-0.6902	-0.6474	-0.563888
sigma	1.117215	0.041523	1.039000	1.0890	1.1160	1.1440	1.202000

Taula 4.4 Percentils β_0 , β_1 i σ Model 2 EVH

Abans de posar-nos a comentar els mapes, amb les estimacions puntuals i per interval dels paràmetres podem veure que els valors esperats d'esperança de vida per a ABS que tenen un índex de privació 0 són de 81.84 anys amb el cas dels homes i 86.22 amb el cas de les dones. Aquesta diferència ja l'esperàvem ja que al model 1 ja hem vist comportaments similars.

El que ens sembla molt curiós i interessant és la interpretació del paràmetre β_1 que com hem dit ja anteriorment el signe lògic que esperàvem del paràmetre és el negatiu, aquesta hipòtesi que fèiem veiem que es compleix. El que ja no era tant esperable és la magnitud d'aquest valor, veiem que per les dones és de -0.16 i pels homes -0.69 . Pels homes aquest paràmetre és aproximadament 4 cops més gran. Els resultats obtinguts es poden interpretar com que el fet de viure en un ambient socioeconòmic baix disminueix molt més l'esperança de vida dels homes que de les dones.

Figura 4.7 Model 2 Esperança de Vida Dones de Catalunya

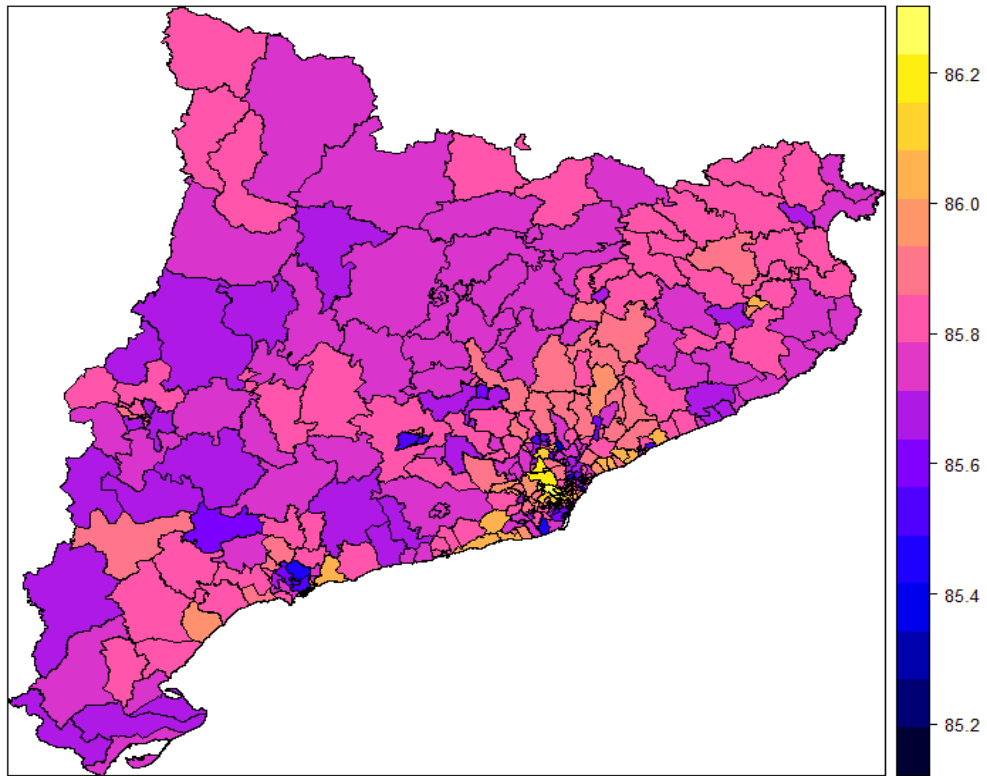
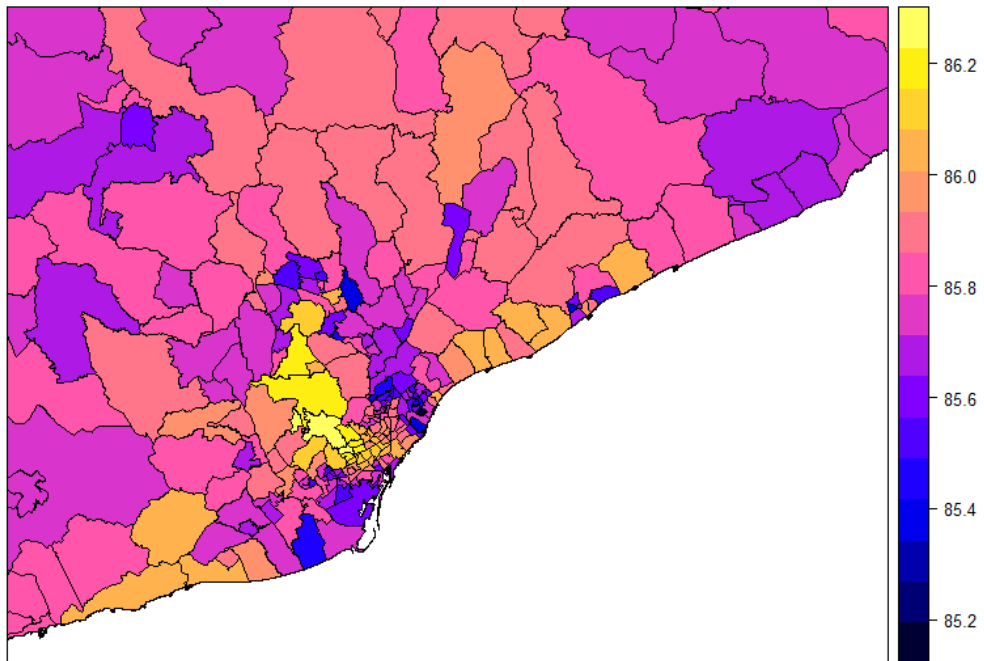


Figura 4.8 Model 2 Esperança de Vida Dones de l'Àrea Metropolitana



Respecte al mapa de l'esperança de vida de les dones, Figura 4.7, podem veure que les àrees més extremes semblen estar a l'àrea metropolitana, que és on es veuen valors grocs, esperances de vida d' aproximadament 86.2, que és la que segons el model prenen les ABS amb l'índex de privació igual a 0. I els valors blaus d' aproximadament 85.2 . És curiós veure com segons aquest model les prediccions més altes i més baixes només varien 1 any entre elles.

Aquest model té el mateix comportament que el mapa de l'índex de privació però canviat de signe així que veient la informació que teníem allà, podem obtenir quines són les ABS extremes. Constantí (107) té un índex de privació molt alt, per tant té una esperança de vida baixa.

Com ja dèiem a nivell metropolità, Figura 4.8, podem veure diferències clares d'esperança de vida, podem veure que l'ABS Badalona 5 (276), Sabadell 7 (198), Mataró 6 (157) i Sant Adrià del Besos 2 (312), que tenien índex de privació alts, en aquest model presenten esperances de vida baixes.

Com a contraposició, ABS amb esperances de vida alta són les ABS 44 i 45 que pertanyen al districte de Sarrià-Sant Gervasi, que són les que tenien índexs de privació més baixos, a part d'aquestes també tenim valors alts a les ABS 389 i 390 que són Sant Cugat del Vallès 2 i Sant Cugat del Vallès 3. I a nivell de Barcelona també tenim ABS amb el mateix color de les de Sant Cugat que són les ABS 40,42,43 i 46 que la primera pertany al districte de Les Corts i la resta al districte de Sarrià-Sant Gervasi.

Pel que fa als homes és bàsicament el mateix, Figura 4.9 i Figura 4.10, únicament canviant l'escala, que en aquest cas va de 77.5 anys a 82. Entre l'ABS amb més esperança de vida i la que menys hi ha 4.5 anys de diferència. Més de 4 cops més que amb les dones, aquest fet el provoca el paràmetre β_1 com ja hem dit anteriorment.

En els mapes podem veure que les ABS amb esperança de vida alta al mapa de les dones són les que també són altes amb els homes, i amb les baixes passa el mateix. Per tant obtenim els mateixos resultats:

Constantí (107) té un índex de privació molt alt, per tant té una esperança de vida baixa. Com ja dèiem a nivell metropolità podem veure diferències clares d'esperança de vida, podem veure que Badalona 5 (276), Sabadell 7 (198) , Mataró 6 (157) i Sant Adrià del Besos 2 (312), que tenien índex de privació alts, en aquest model presenten esperances de vida baixes.

Com a contraposició, ABS amb esperances de vida alta són les ABS 44 i 45 que pertanyen al districte de Sarrià-Sant Gervasi, que són les que tenien índexs de privació més baixos, a part d'aquestes també tenim valors alts a les ABS 389 i 390 que són Sant Cugat del Vallès 2 i Sant Cugat del Vallès 3. I a nivell de Barcelona també tenim ABS amb el mateix color de les de Sant Cugat que són les ABS 40,42,43 i 46 que la primera pertany al districte de Les Corts i la resta al districte de Sarrià-Sant Gervasi.

Figura 4.9 Model 2 Esperança de Vida Homes de Catalunya

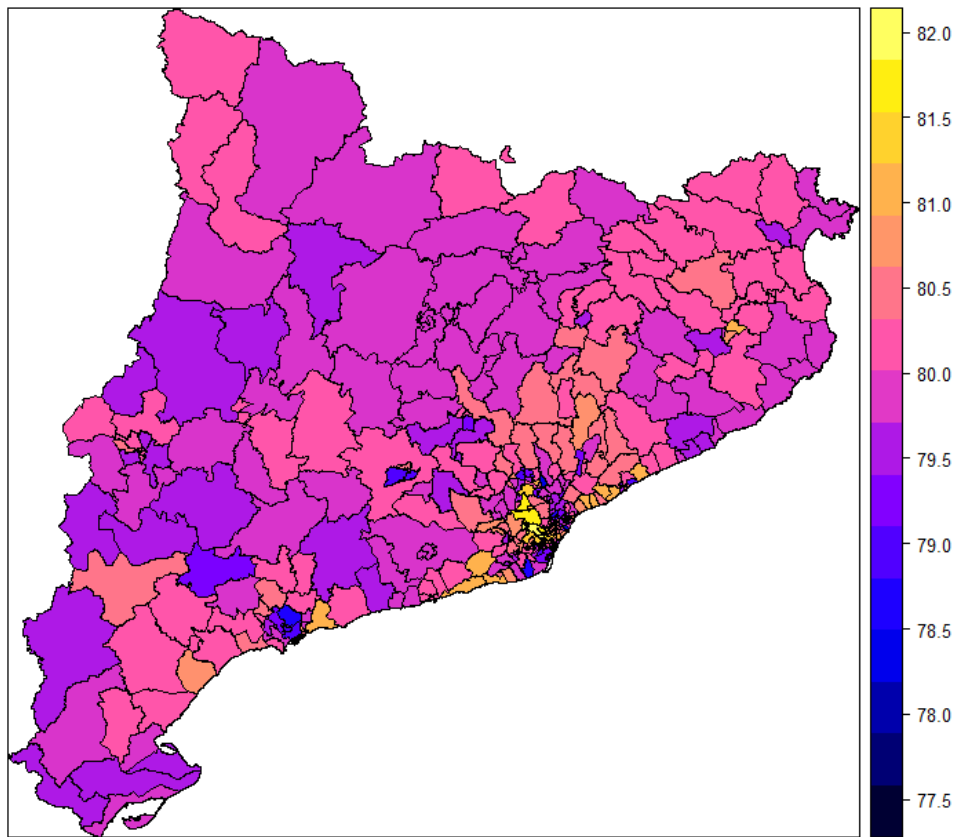
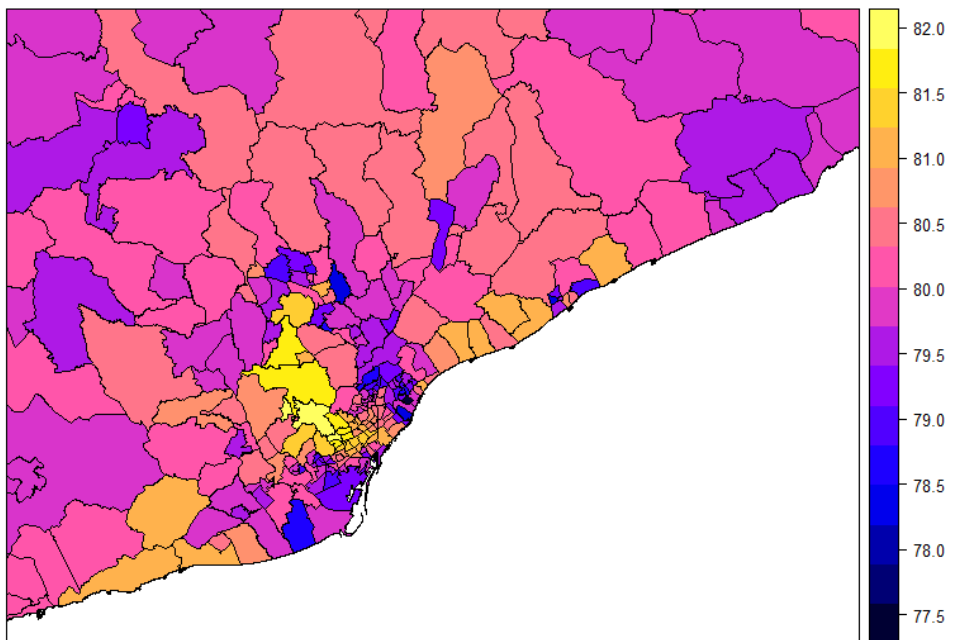


Figura 4.10 Model 2 Esperança de Vida Homes de l'Àrea Metropolitana



4.3 Model 3: Estructura espacial com a predictor lineal

El model 3 a diferència dels dos models anteriors té un paràmetre que té en compte l'estructura espacial de les dades, és a dir les prediccions tenen dos paràmetres: β_0 que és un paràmetre comú de tots els individus, i el seu significat és el valor mitjà de totes les ABS, és la μ del model 1. També γ_i que és un paràmetre espacial que permet que les àrees veïnes tinguin estimacions més semblants que no pas àrees allunyades.

Si γ_i té un valor positiu el significat és que les ABS veïnes de l'ABS en qüestió tenen una mitjana més gran de la mitjana global. Si és negatiu la mitjana de les ABS és menor a la mitjana global. Escrivim el model com:

$$EV_i | \beta_0, \sigma, \sigma_v \sim \text{Normal}(\beta_0 + \gamma_i, \sigma)$$

$$\gamma_i | \sigma_v, \gamma_{-i} \sim \text{Normal}(\bar{Y}_{v(i)}, \sigma_v)$$

$$\bar{Y}_{v(i)} = \frac{1}{n_i} \sum_{j \in V(i)} Y_j$$

,on $V(i)$ és el conjunt de ABS veïnes de la ABS i -èsima, i n_i el seu nombre de ABS adjacents.

$$\beta_0 \sim \text{Normal}(80, 10)$$


$$\sigma \sim \text{Unif}(0,10)$$

$$\sigma_v \sim \text{Unif}(0,10)$$

El model 3 suposa que el valor esperat d'EV per a una ABS està centrat en la mitjana del valor esperat de l'EV de les àrees adjacents o veïnes a aquesta. La funció que fa això a WINBUGS està parametritzada per incloure una restricció de suma a zero, de manera que hem d'incloure un terme independent al model, que serà la mitjana de l'EV de totes les ABS, en aquest cas. Les prioris que hem escollit, que són poc informatives, suposen que aquest terme independent comú per a totes les ABS, β_0 , estarà entre 60 i 100 amb un 95% de probabilitat. Respecte a la desviació típica de l'EV i la desviació típica del paràmetre espacial hem triat unes prioris que donen la mateixa probabilitat a tots els valors de l'interval de 0 a 10. Si representem les posteriors:

En el cas de les dones, Figura 4.11, veiem que la posteriori de la β_0 (a0 a la taula 4.5) està centrada en aproximadament 85.79, i l'interval de credibilitat al 95% de β_0 és [85.68,85.90]. Per la σ veiem que la posteriori està centrada en aproximadament 1.09, i l'interval de credibilitat al 95% de σ és [0.98,1.21]. Per la σ_v (sigma.b a la taula) veiem que la posteriori està centrada en aproximadament 0.77, i l'interval de credibilitat al 95% de σ_v és [0.45,1.17].

Figura 4.11 Posterioris Model 3 EVD




a0	85.791695	0.057841	85.680000	85.750000	85.790000	85.830000	85.900000
sigma	1.094056	0.057227	0.979400	1.057000	1.094000	1.132000	1.206000
sigma.b	0.777100	0.185073	0.454897	0.646600	0.765800	0.893950	1.172000

Taula 4.5 Percentils β_0 , σ , σ_v Model 3 EVD

En el cas dels homes, Figura 4.12, veiem que la posteriori de la β_0 (a0 a la taula 4.6) està centrada en aproximadament 80.04, i l'interval de credibilitat al 95% de β_0 és [79.94,80.15]. Per la σ veiem que la posteriori està centrada en aproximadament 0.97, i l'interval de credibilitat al 95% de σ és [0.81,1.13]. Per la σ_v (sigma.b a la taula) veiem que la posteriori està centrada en aproximadament 1.41, i l'interval de credibilitat al 95% de σ_v és [0.95,1.83].

Figura 4.12 Posterioris Model 3 EVH



a0	80.044857	0.053142	79.940000	80.010000	80.050000	80.080000	80.150000
sigma	0.976033	0.083434	0.810792	0.921400	0.977600	1.033000	1.134000
sigma_b	1.407487	0.224870	0.955195	1.259000	1.410000	1.558250	1.838025

Taula 4.6 Percentils β_0 , σ , σ_b Model 3 EVH

Figura 4.13 Model 3 Esperança de Vida Dones de Catalunya

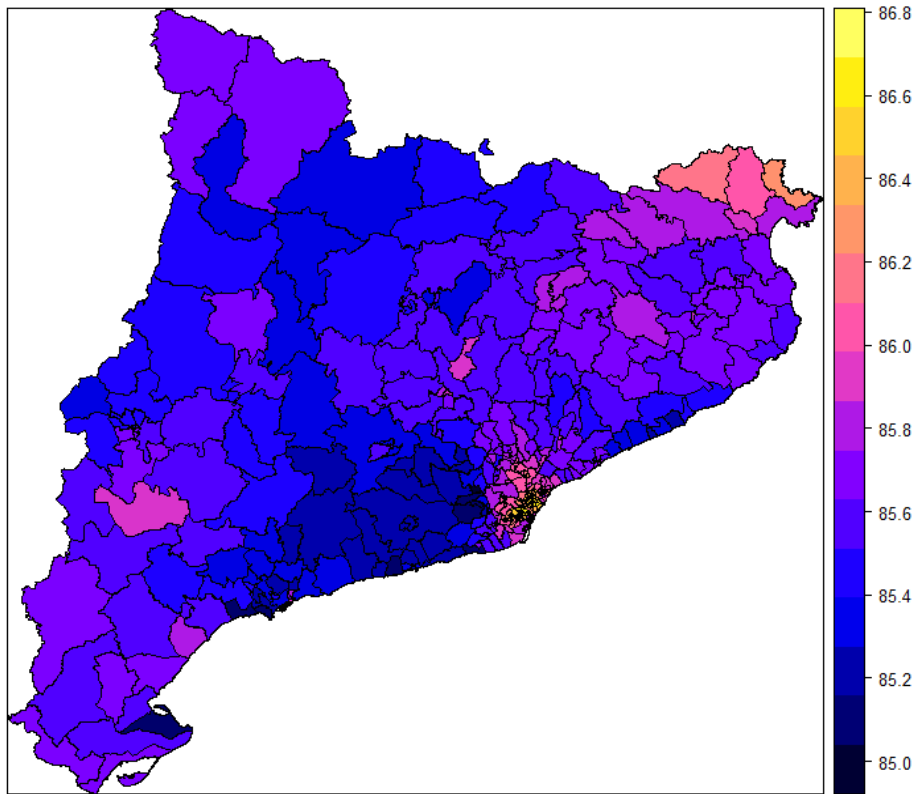
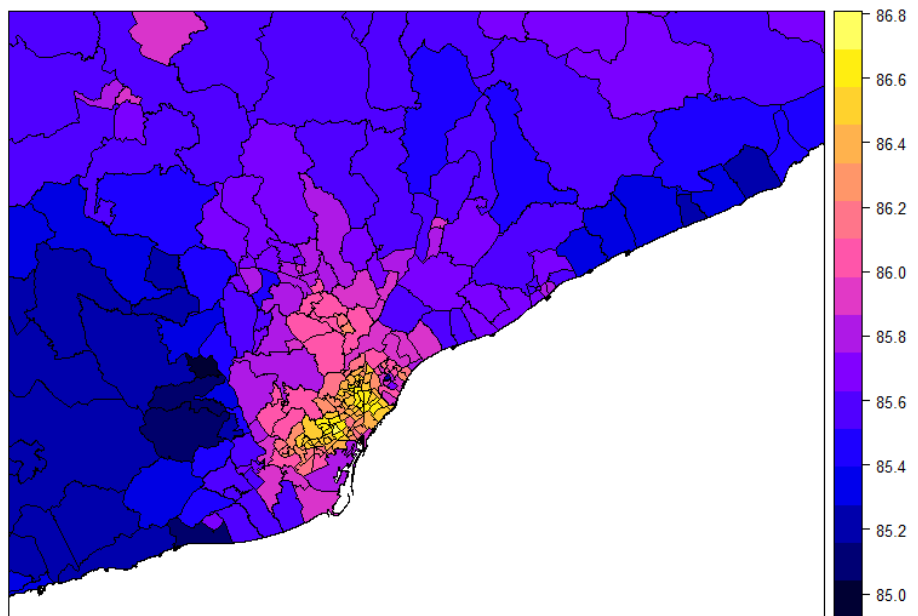


Figura 4.14 Model 3 Esperança de Vida Dones de l'Àrea Metropolitana



Respecte als resultats per dones, Figura 4.13, podem veure que les ABS amb més esperança de vida estan a la zona metropolitana. Vist al mapa de Catalunya podem veure que les ABS del nord Llançà (134), La Jonquera (133) i Peralada (177) tenen esperances de vida altes. En canvi veiem que la ABS 113 té una esperança de vida baixa. Podem veure que en aquest model el rang de valors és força petit, va dels 85 anys als 86.8.

Quant a l'àrea metropolitana, Figura 4.14, veiem que l'ABS de Sant Andreu de la Barca (201), té una esperança de vida molt baixa. En quan a esperances de vida alta en trobem unes quantes ABS: Són ABS que pertanyen als districtes de Sarrià-Sant Gervasi (44 i 42), Les Corts (40 i 39), Eixample (23 i 25), Sant Martí (73,331,77,75,76), Horta-Guinardó (326), Sant Andreu (67), Nou Barris (385,57,59). Com veiem, Figura 4.14, dins de Barcelona hi ha dos grups de veïnatsges amb esperances de vida altes.

Respecte els homes, Figura 4.15, no es veu cap territori que sigui extrem, les ABS que podem trobar més extremes són en quant a valors baixos les ABS de Sant Quirze de Besora (217) i Ribes de Freser – Campdevànol (343). Dir que en els homes l'escala de valors és molt més ample, va de 77.5 a aproximadament 82. Anem a fer zoom a l'àrea metropolitana, tot i que ara no s'hi intueix un comportament tant diferent com en mapes anteriors.

A l'àrea metropolitana, Figura 4.16, podem veure que l'ABS de Sant Adrià del Besos 2 (312) presenta un valor molt baix. Tot i que els valors veïns no són tant baixos. Les ABS amb valors alts són les ABS 44 i 40 que són dels districtes de Sarrià-Sant Gervasi i Les Corts respectivament. En aquest mapa hem de dir que no hi ha gaires valors extrems.

Figura 4.15 Model 3 Esperança de Vida Homes de Catalunya

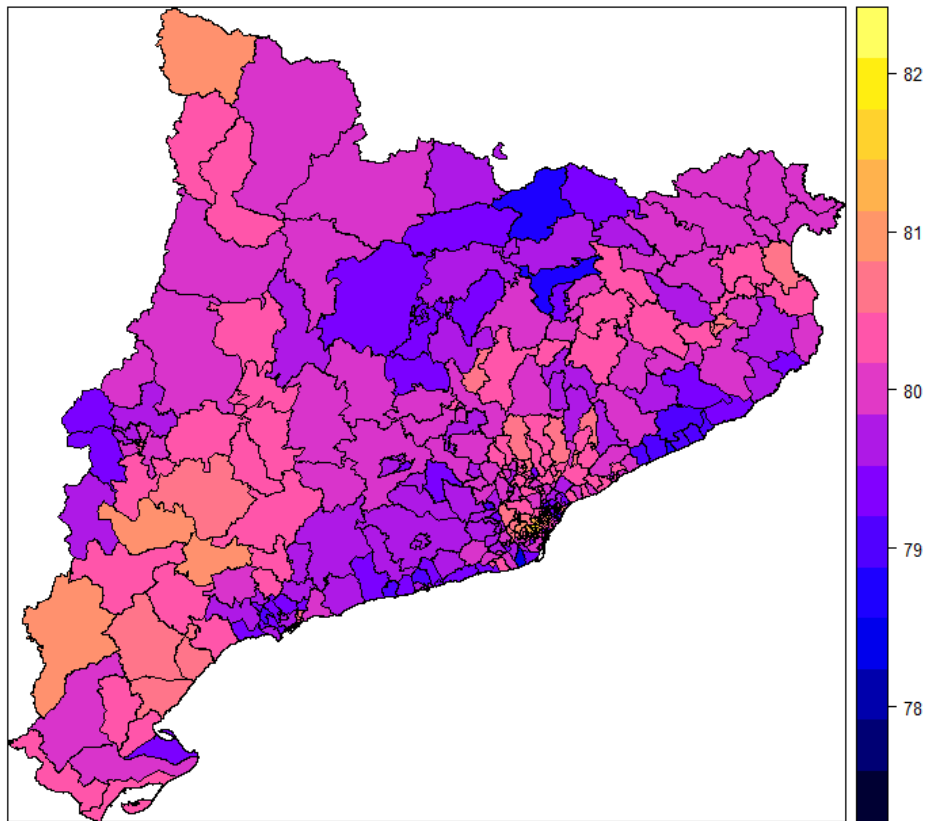
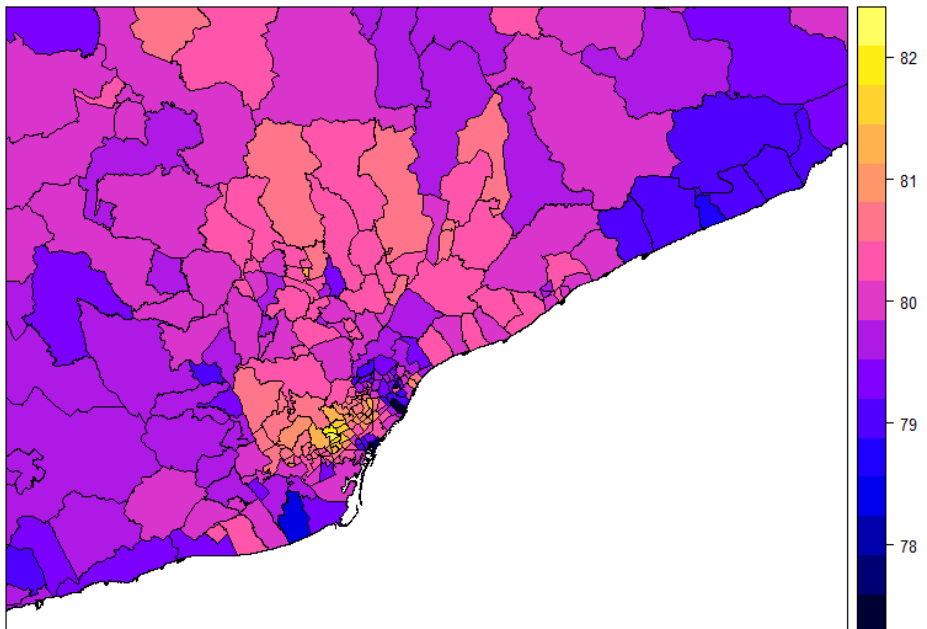


Figura 4.16 Model 3 Esperança de Vida Homes de l'Àrea Metropolitana



4.4 Model 4: Estructura espacial i índex de privació com a predictor lineal

El model 4 és el model més complet de tots ja que té 3 paràmetres β_0 , β_1 i γ_i que modulen el valor esperat. β_0 representa l'esperança de vida d'una ABS que el seu índex de privació és 0, també es pot considerar com la mitjana global de totes les ABS, i el segon β_1 és el nombre d'anys que canvia l'esperança de vida quan augmenta una unitat l'índex de privació. El signe esperat d'aquest paràmetre és el signe negatiu, és a dir com més nivell socioeconòmic tingui la esperança de vida, més baix sigui l'índex de privació, més alta serà l'esperança de vida. Per últim tenim el paràmetre γ_i que és un paràmetre espacial que permet modelar la correlació. Si γ_i té un valor positiu, el significat és que les ABS veïnes de l'ABS en qüestió tenen una mitjana més gran de la mitjana global. Si és negatiu, la mitjana de les ABS és menor a la mitjana global. Escrivim el model com:

$$EV_i \mid \beta_0, \beta_1, \sigma, \sigma_v \sim \text{Normal}(\beta_0 + \beta_1 * IP_i + \gamma_i, \sigma)$$

$$\gamma_i \mid \sigma_v, \gamma_{-i} \sim \text{Normal}(\bar{\gamma}_{v(i)}, \sigma_v)$$

$$\bar{\gamma}_{v(i)} = \frac{1}{n_i} \sum_{j \in V(i)} \gamma_j$$

,on $V(i)$ és el conjunt de ABS veïnes de la ABS i -èsima, i n_i el seu nombre de ABS adjacents.

$$\beta_0 \sim \text{Normal}(80, 10)$$

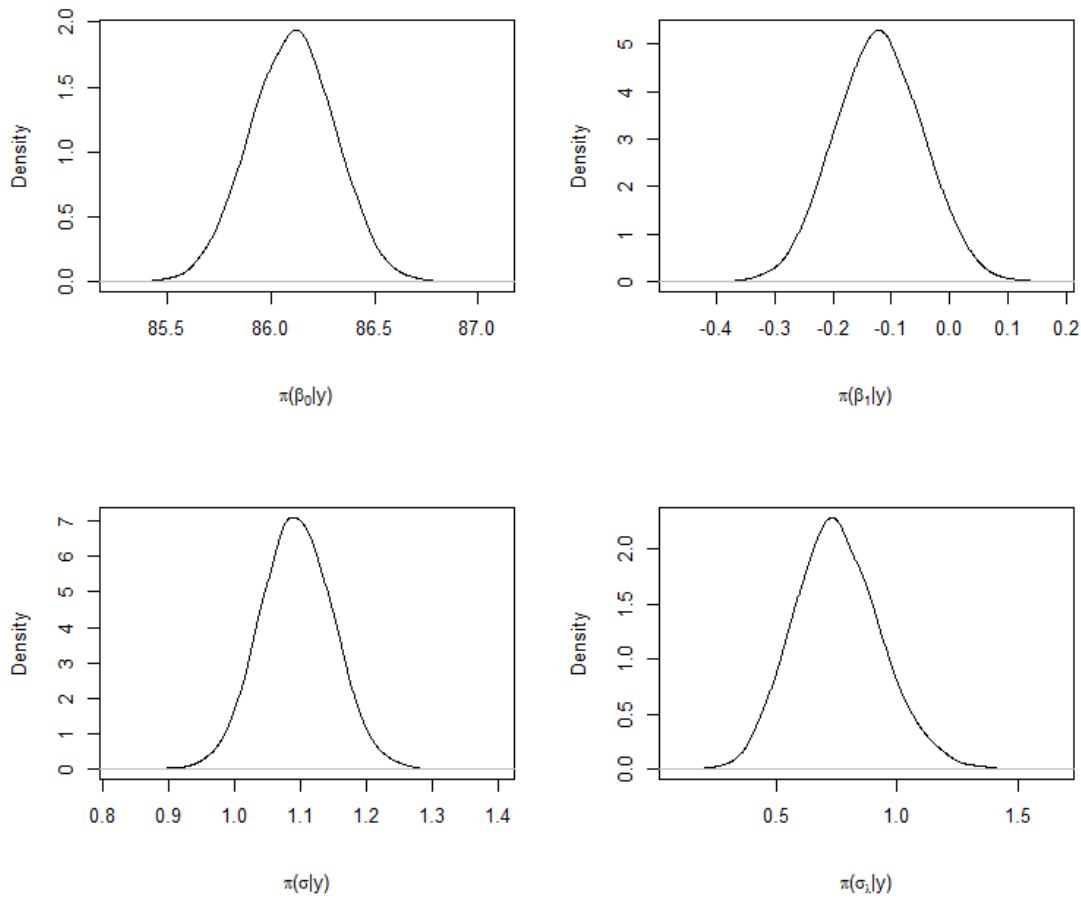
$$\beta_1 \sim \text{Normal}(0, 10)$$

$$\sigma \sim \text{Unif}(0, 10)$$

$$\sigma_v \sim \text{Unif}(0, 10)$$

El model 4 a part d'incorporar l'estructura espacial del Model 3 també utilitza l'índex de privació com a variable explicativa. En aquest model també tenim terme independent com en l'anterior, en aquest cas les prioris que hem escollit, que són poc informatives, suposen que aquest terme independent comú per a totes les ABS estarà entre 60 i 100 amb un 95% de probabilitat i que el valor esperat del coeficient que multiplica l'índex de privació estarà entre -20 i 20 amb un 95% de probabilitat. Respecte a la desviació típica de l'EV i la desviació típica del paràmetre espacial hem triat unes prioris que donen la mateixa probabilitat a tots els valors de l'interval de 0 a 10.

Figura 4.17 Posterioris Model 4 EVD

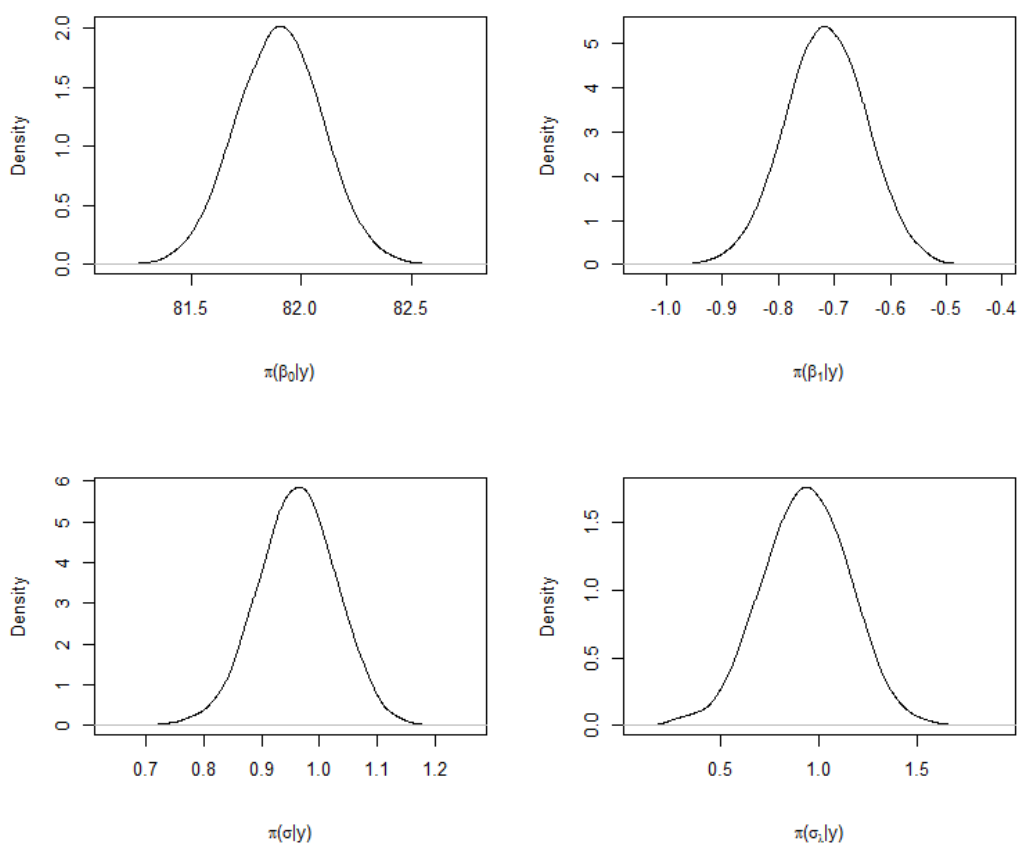


En el cas de les dones veiem, tant a la Figura 4.17 com a la Taula 4.7, que la posteriori de la β_0 (a0 a la taula) està centrada en aproximadament 86.10, i l'interval de credibilitat al 95% de β_0 és [85.71,86.49]. Per la β_1 (c a la taula) veiem que la posteriori està centrada en aproximadament -0.12, i l'interval de credibilitat al 95% de β_1 és [-0.27,0.03]. Per la σ veiem que la posteriori està centrada en aproximadament 1.09, i l'interval de credibilitat al 95% de σ és [0.99,1.20]. Per la σ_v (a la taula sigma.b) veiem que la posteriori està centrada en aproximadament 0.76, i l'interval de credibilitat al 95% de σ_v és [0.43,1.13].

a0	86.106168	0.202628	85.710000	85.970000	86.110000	86.240000	86.490000
sigma	1.095244	0.055178	0.987897	1.059000	1.095000	1.132000	1.203000
sigma.b	0.755681	0.178826	0.430900	0.632550	0.746150	0.870400	1.134000
c	-0.120902	0.075002	-0.265202	-0.171600	-0.121400	-0.070350	0.025432

Taula 4.7 Percentils $\beta_0, \beta_1, \sigma, \sigma_v$ Model 4 EVD

Figura 4.18 Posterioris Model 4 EVH



En el cas dels homes veiem, tant en la Figura 4.18 com en la Taula 4.8, que la posteriori de la β_0 (a0 a la taula) està centrada en aproximadament 81.90, i l'interval de credibilitat al 95% de β_0 és [81.52,82.28]. Per la β_1 (c a la taula) veiem que la posteriori està centrada en aproximadament -0.71, i l'interval de credibilitat al 95% de β_1 és [-0.85,-0.58]. Per la σ veiem que la posteriori està centrada en aproximadament 0.96, i l'interval de credibilitat al 95% de σ és [0.83,1.09]. Per la σ_v (sigma.b a la taula) veiem que la posteriori està centrada en aproximadament 0.93, i l'interval de credibilitat al 95% de σ_v és [0.49,1.36].

a0	81.899894	0.193412	81.520000	81.770000	81.90000	82.0300	82.280000
sigma	0.961648	0.067457	0.825697	0.917575	0.96260	1.0070	1.090000
sigma.b	0.932626	0.221088	0.494592	0.785900	0.93625	1.0840	1.357025
c	-0.714967	0.071856	-0.858202	-0.762825	-0.71520	-0.6660	-0.575593

Taula 4.8 Percentils $\beta_0, \beta_1, \sigma, \sigma_v$ Model 4 EVH

Figura 4.19 Model 4 Esperança de Vida Dones de Catalunya

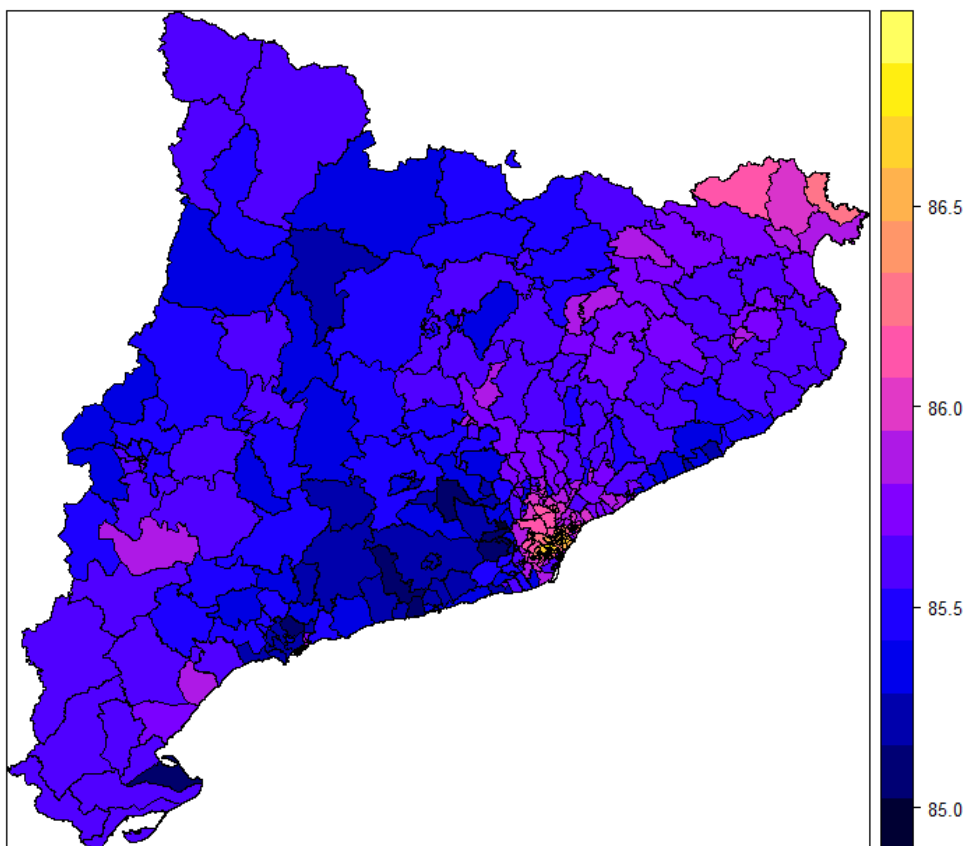
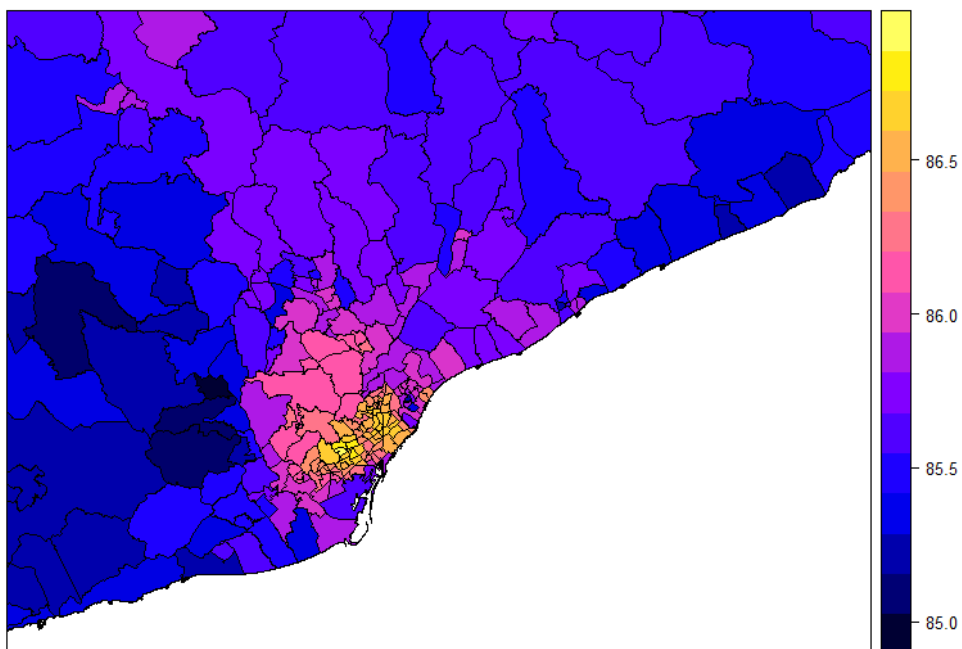


Figura 4.20 Model 4 Esperança de Vida Dones de l'Àrea Metropolitana



Pel que fa als resultats per dones, Figura 4.19, podem veure que les ABS amb més esperança de vida estan a la zona metropolitana. Vist al mapa de Catalunya podem veure que les ABS del nord Llança (134), La Jonquera (133) i Peralada (177) tenen esperances de vida altes. En canvi veiem que la ABS Deltebre (113) té una esperança de vida baixa. Podem veure que en aquest model, el rang de valors és força petit, va dels 85 anys als 86.8. Aquest gràfic tot i ser un model diferent és gairebé igual al model 3, respecte a àrees extremes en quant a valors, no es veuen diferències.

Quant a l'àrea metropolitana, veiem que l'ABS 201, Sant Andreu de la Barca, té una esperança de vida molt baixa. En quan a esperances de vida alta en trobem unes quantes ABS:

Que són ABS que pertanyen al districte de Sarrià-Sant Gervasi (44 i 42), Les Corts (40), Eixample (23) En aquest cas veiem que moltes àrees que abans eren altes en quant a esperança de vida a l'afegir l'índex de privació han deixat de ser els valors més alts.

Respecte als homes, en aquest gràfic, Figura 4.21, no es veuen aparentment ABS amb valors extrems. Bàsicament comentar que les esperances de vida van dels 77.5 aproximadament als 82.5 aproximadament. Però en canvi a l'àrea metropolitana es veuen més àrees de valors alts, que suposadament són les àrees amb índexs de privació amb valors baixos.

A l'àrea metropolitana podem veure ABS amb valors baixos com l'ABS de Badalona 5(276), Sabadell 7 (198), Mataró 6 (157) i Sant Adrià del Besòs 2 (312), que són els que tenen ABS amb índexs de privació alts. A part amb valors baixos tenim l'ABS del Prat de Llobregat 3 (184) que tot i no ésser un índex de privació tant extrem, però també és alt.

Quant a valors alts d'esperança de vida trobem les ABS 40 i 41 que pertanyen al districte de Les Corts, i les ABS (42, 43, 44, 45, 46) que pertanyen al districte de Sarrià-Sant Gervasi, Sant Cugat del Vallès 2 (389) i Sant Cugat del Vallès 3 (390).

Figura 4.21 Model 4 Esperança de Vida Homes de Catalunya

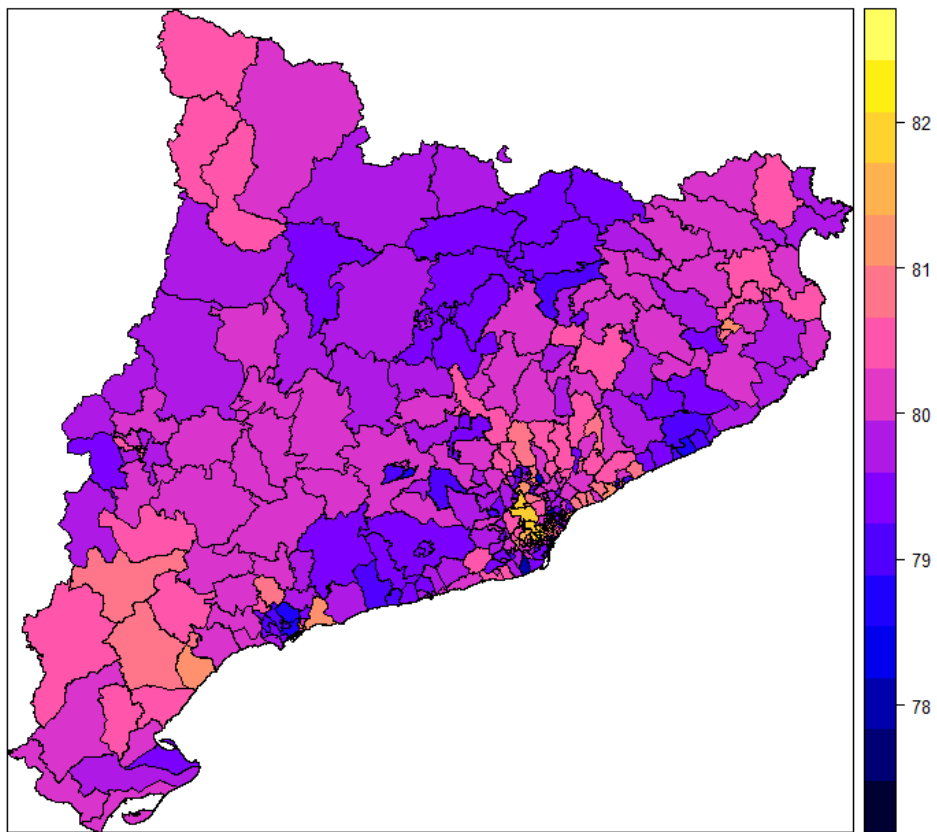
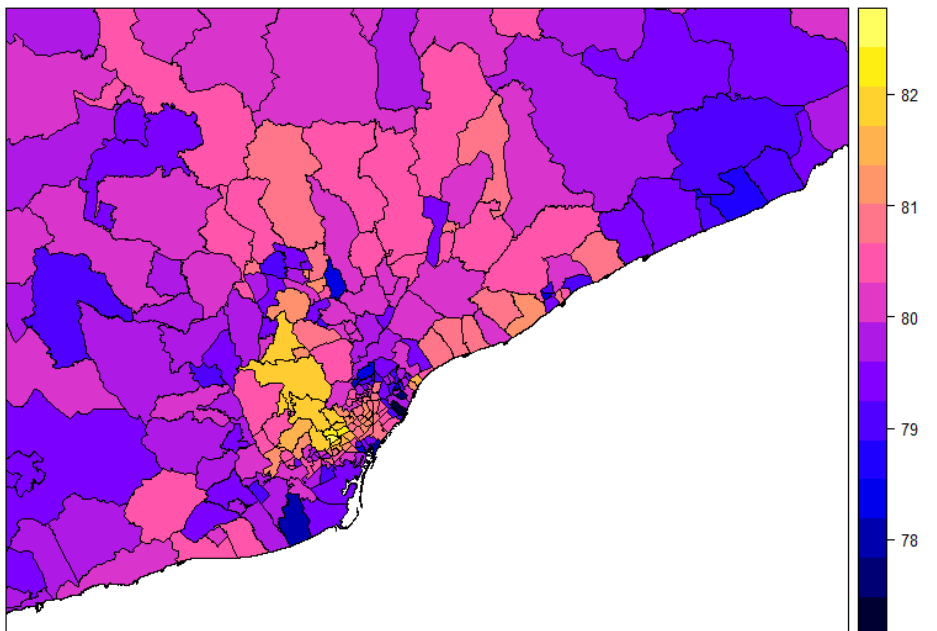


Figura 4.22 Model 4 Esperança de Vida Homes de l'Àrea Metropolitana



4.5 Implementació Models

Per a implementar els models 2 i 4, la variable predictora de l'índex de privació ha d' estar completa, no pot tenir valors missings, ja que sinó el WINBUGS no deixa executar el model. Aquestes prediccions no estaran representades al mapa de l'índex de privació, sinó que hi serà representat el valor NA.

Per les ABS de nova creació que anteriorment formaven part d'altres ABS, utilitzarem l'índex de privació de l'ABS d'on prové. O la mitjana dels índexs de privació quan es tracta d'una ABS nova que es crea a partir de 2 ABS. Aquests casos són les ABS: 399,382,381,393,394,400,398,401,397.

Pels missings estructurals que són les ABS a les quals no es va calcular l'índex en aquell moment utilitzarem la següent fórmula.

La calcularem per a les ABS 7 i 379.

$$IP_i = \frac{\overline{IP} + \overline{IP}_{V(i)}}{2}$$

$$\text{On } \overline{IP} = \frac{\sum_{i=1}^n IP_i}{n}$$

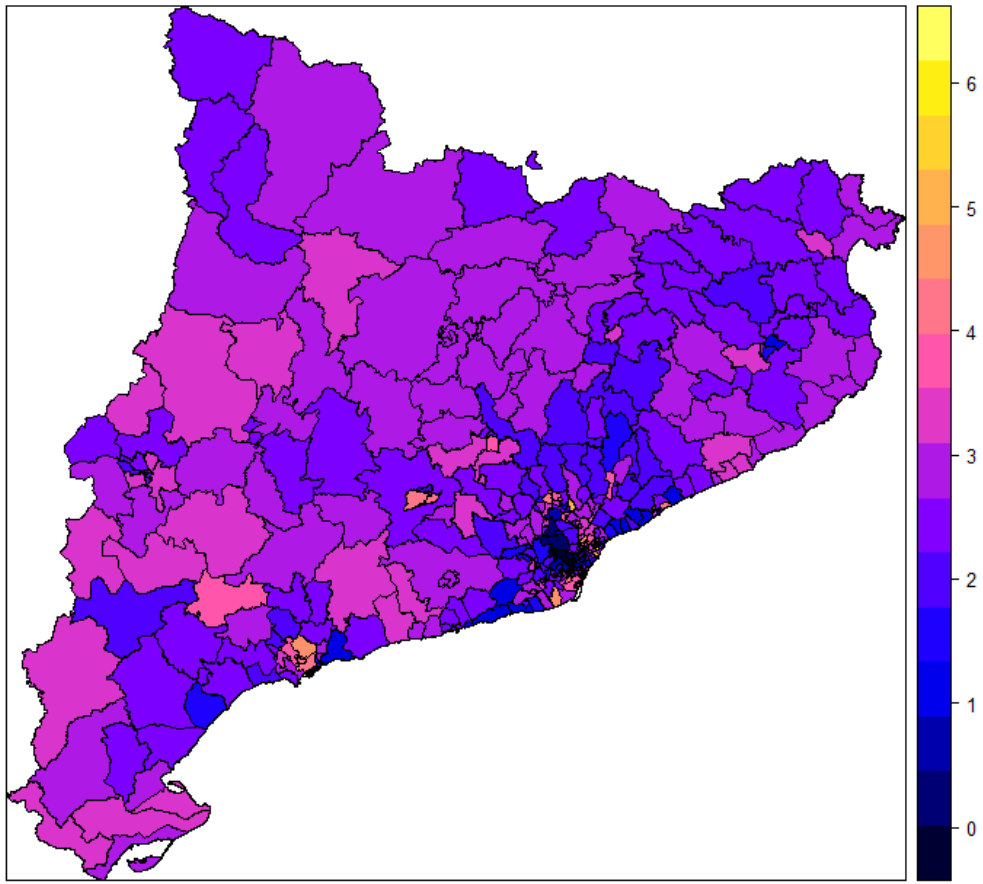
V(i) són els veïns de l'àrea i per tant $\overline{IP}_{V(i)}$ és la mitjana de l'índex de privació dels veïns de l'àrea i.

La fórmula prediu l'índex de privació per a aquestes 2 àrees com la mitjana de la mitjana de l'índex de privació de totes les ABS i la mitjana de l'índex de privació del veïns. A la Figura 4.23 podem veure el mapa per ABS amb els valors imputats.

Per a implementar els models 3 i 4 hem de tenir una matriu de veïnatges, que hem calculat amb R amb la funció *poly2nb* del paquet *sdep*. Aquesta funció crea una matriu de 1 i 0 on si la ABS_i i la ABS_j tenen un vèrtex o aresta en comú pren el valor 1, altrament 0.

Un cop solucionats aquests problemes, hem implementat els models amb el programa de lliure distribució WINBUGS.

Figura 4.23 Índex de privació amb imputacions



5. SELECCIÓ I VALIDACIÓ MODELS

En aquest capítol escollirem quin és el millor model per a predir l'esperança de vida en àrees petites i a part farem les comprovacions pertinents per a considerar que en aquests models expliquen bé les dades i que són bons i útils per a predir el que volem. Aquestes comprovacions seran: normalitat, homoscedasticitat i linealitat dels residus i comprovar que no hi hagi un excés de autocorrelació espacial dels residus.

5.1 Selecció del model

Per a tal de seleccionar quin és el model que explica millor les nostres dades ho farem mitjançant el DIC (Deviance information criterion), el model que tingui el DIC menor és el que millor s'ajusta a les dades, per tant amb el que ens quedarem.

El DIC és un estadístic que ens proporciona informació sobre quin model seleccionar. No és un estadístic de bondat absoluta dels models, sinó relativa, és a dir que el que et diu es que d'una llista de models quin és el millor d'ells. El millor model és el que té el DIC més baix. El DIC es calcula utilitzant la deviança i afegint un terme penalitzador relacionat amb la complexitat del model. El seu anàleg en l'estadística freqüentista és l'AIC (Akaike information criterion).

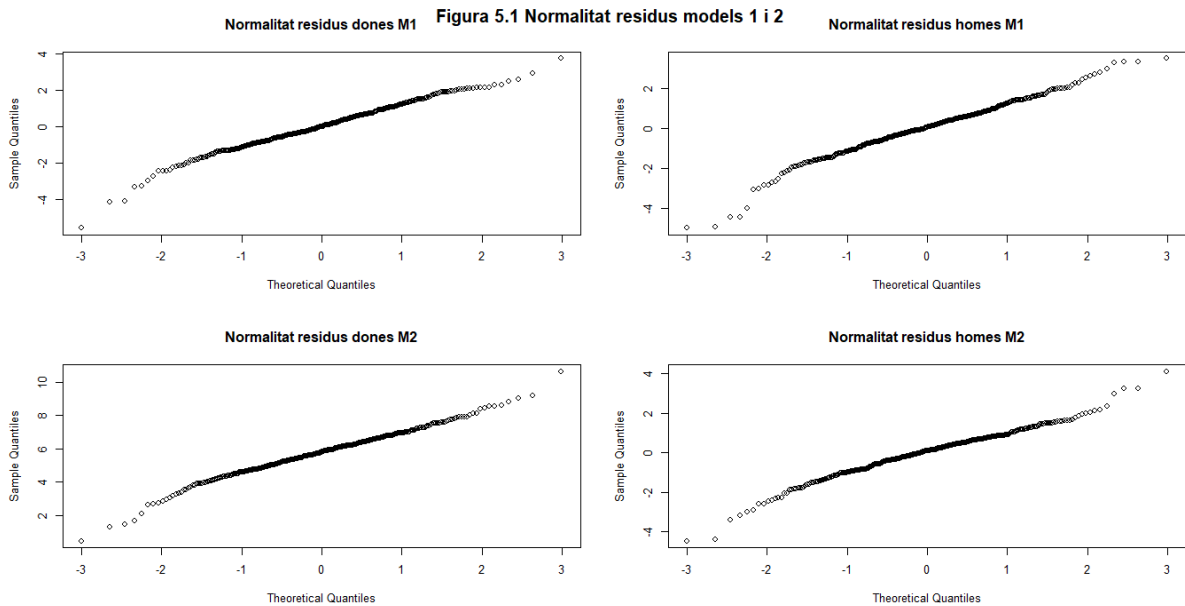
Tant en el cas dels homes com en el de les dones seleccionarem com a millor model el model 4, que és el que té el DIC més baix. En el cas de les dones ho és per molt poc, tots els models donen DIC semblants, en canvi amb els homes hi ha més diferència.

Models	DIC	
	Homes	Dones
Model 1	1201.7	1174.1
Model 2	1102.8	1170.5
Model 3	1119	1133.8
Model 4	1066.4	1133.6


Taula 5.1 DIC per model i sexe

5.2 Validació dels models

Anem a dur a terme les validacions dels models. Mirarem normalitat dels residus, homoscedasticitat, linealitat i independència. La independència la validarem calculant l'autocorrelació espacial dels residus.

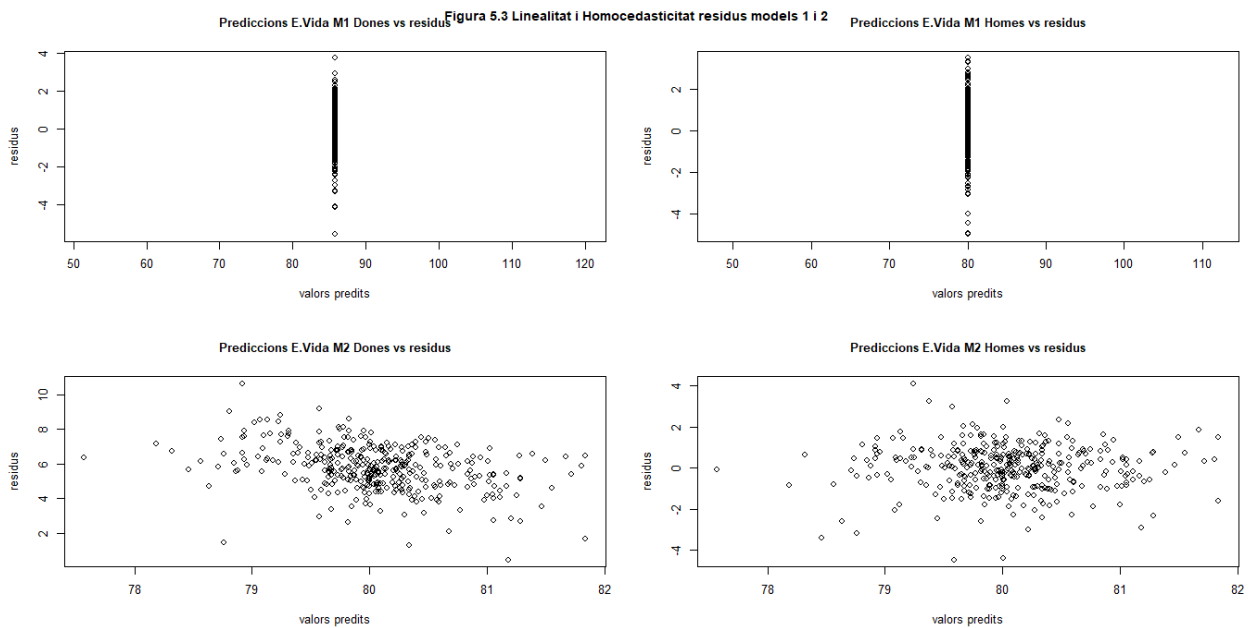


Podem veure, a la Figura 5.1, que per els dos sexes, tant en el model 1 com en el model 2 no es veu res estrany analitzant la normalitat dels residus.



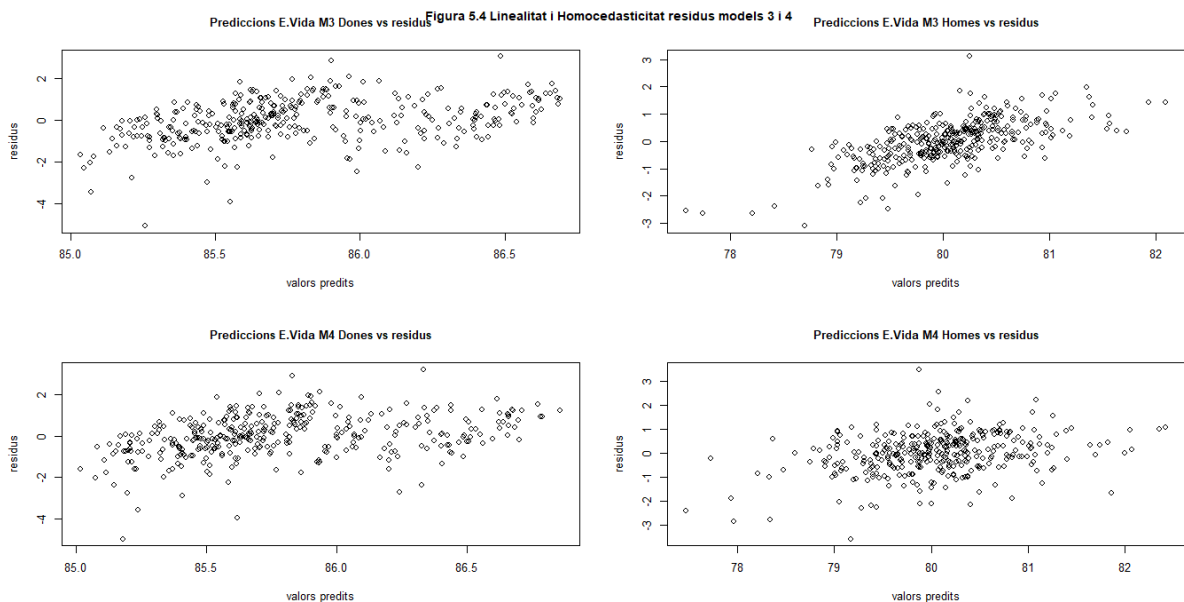
Per als models 3 i 4 per als dos sexes podem veure a la Figura 5.2 que tampoc.

Tot seguit intentarem mirar la linealitat i homoscedasticitat dels residus:



A la Figura 5.3, veiem que al model 1 tenim problemes ja que totes les ABS tenen la mateixa predicció, tot i això com que és el model amb un DIC més alt ja sabem que no l'escolliríem.

Respecte al model 2 no veiem cap problema de residu, veiem el típic patró amb el que surten aquests gràfics, núvol de punts amb direcció horitzontal amb amplada vertical constant. Amb la qual cosa podem validar les hipòtesis de linealitat i homoscedasticitat del model 2 per els dos sexes.



Respecte al model 3, podem veure, a la Figura 5.4, que pel cas dels homes es veu una relació lineal entre els residus i les prediccions, això pot indicar que alguna variable no inclosa en el model pot ser significativa com en el nostre cas és l'índex de privació. Ja que en el cas dels homes del model 4 que

justament hi hem afegit aquesta variable, podem donar els residus com a vàlids, ja que veiem el núvol de punts que té direcció horitzontal amb amplada vertical constant. Amb la qual cosa podem validar les hipòtesis de linealitat i homoscedasticitat del model 4 pel cas dels homes però no podem validar el model 3 pel cas dels homes. Respecte al cas de les dones podem donar com a vàlids tots 2 models.

Ara per ara només podríem donar per a vàlids pels dos sexes els models 2 i 4.

Un cop fetes les clàssiques validacions de residus, farem les comprovacions pertinents per intentar veure que no hi hagi un excés d'autocorrelació espacial, per a garantir la independència de les dades. Aquesta validació és pròpia dels models de dades espacials, on els models es validen si es compleix que la part no explicada del model, els residus, es pot considerar com a independent i idènticament distribuïda, pel contrari si encara hi queda dependència espacial, no es poden validar.

Per analitzar la correlació espacial de qualsevol mesura s'ha de definir el terme veïns, nosaltres considerem dues àrees veïnes, si dues ABS tenen un vèrtex o aresta en comú. I utilitzarem pesos binaris, 1 si són veïns, 0 si no.

Un cop definida l'estructura de veïnatge definirem l'índex que ens mesurarà la correlació espacial, que en el nostre cas és l'índex de Moran. Que es calcula:

$$I = \frac{N}{\sum_i \sum_j w_{ij}} \frac{\sum_i \sum_j w_{ij} (X_i - \bar{X})(X_j - \bar{X})}{\sum_i (X_i - \bar{X})^2}$$

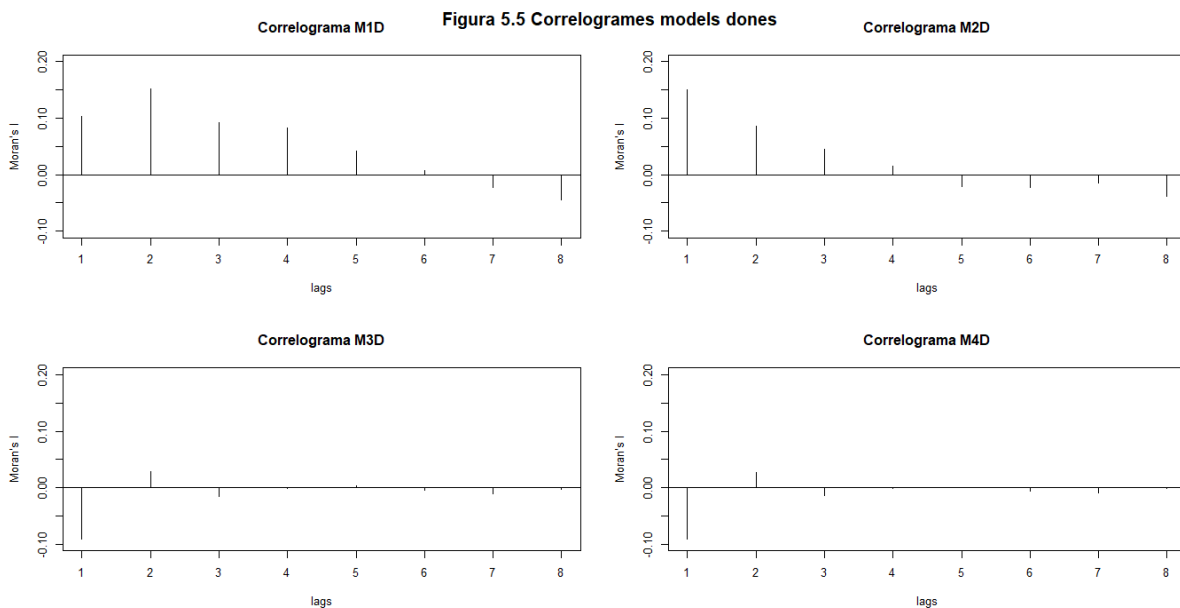
On N és el nombre de ABS w_{ij} és el pes, X_i i X_j són els residus de les ABS i i j respectivament i \bar{X} és la mitjana dels residus.

En el nostre cas analitzarem la correlació mitjançant correlogrames espacials a base de calcular l'índex de Moran, I, reemplaçant els pesos w_{ij} per als dels veïns de primer ordre, segon ordre i així successivament.

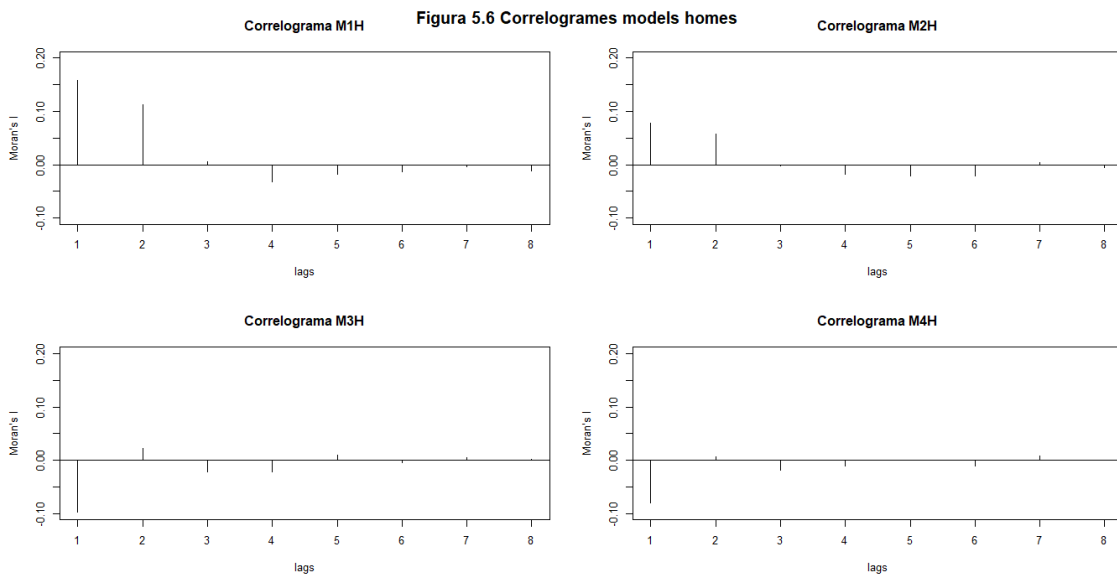
Si són veïns de primer ordre $w_{ij}^1=1$, si no $w_{ij}^1=0$ amb aquests pesos obtindrem l'índex de Moran pels veïns, I^1 . Si dos territoris són veïns de segon ordre, no són veïns de primer ordre i tenen un veí en comú. En aquest cas els pesos si són veïns de segon ordre $w_{ij}^2=1$, si no $w_{ij}^2=0$ i amb aquests pesos es calcula I^2 . I així successivament.

En principi si no hi ha correlació espacial és d'esperar que I^t estigui al voltant de 0 per a tot t. Si hi ha correlació espacial és d'esperar que I^t vagi decreixent i al final fluctuï al voltant de 0.

Un cop explicat això anem a mirar-ho als correlogrames, presentats a les Figures 5.5 i 5.6:



En quant als models de les dones podem veure, Figura 5.5, que els models 1 i 2 tenen força correlació espacial i el 3 i el 4 tot i que el primer valor és alt podem veure que aquesta s'ha reduït força. Ja que en el model 1 i 2 podem veure que els residus d'una ABS depenen dels residus dels veïns, dels veïns dels veïns, fins a dels veïns de ordre 4. En canvi segons els correlogrames, els models 3 i 4 només tenim autocorrelació de residus amb els veïns.



En el cas dels homes, Figura 5.6, podem veure el mateix fenomen però menys exagerat ja que els models 1 i 2 només tenen autocorrelació de residus fins a veïns d'ordre 2. Un cop podem veure que els models que minimitzen l'autocorrelació dels residus són els models 3 i 4.

Amb totes les comprovacions que hem fet per a validar els models podem veure que l'únic model que compleix totes les hipòtesis en els dos sexes és el model 4, que al cap i a la fi era el que havíem seleccionat mitjançant el DIC, que ens indica quin és el model que s'ajusta millor a les dades.

Els correlogrames, ens diuen que per les àrees veïnes dels dos sexes, hi resta una petita correlació negativa entre els residus, en el sentit que els residus alts solien estar a prop dels residus baixos. Per a veure aquest fet situarem els residus al mapa, ho podem veure a les Figures 5.7, 5.8, 5.9 i 5.10 .

Podem veure en el cas de les dones, en les Figures 5.7 i 5.8, que en general passa el que pronosticàvem, al costat d'un residu positiu gran, en solem tenir un de negatiu gran.

Podem veure que en el cas dels homes, Figures 5.9 i 5.10 passa el mateix que en el cas de les dones, al costat d'un residu positiu gran, hi solem trobar un residu negatiu gran.

Figura 5.7 Residus model 4 Dones




Figura 5.8 Residus model 4 Dones

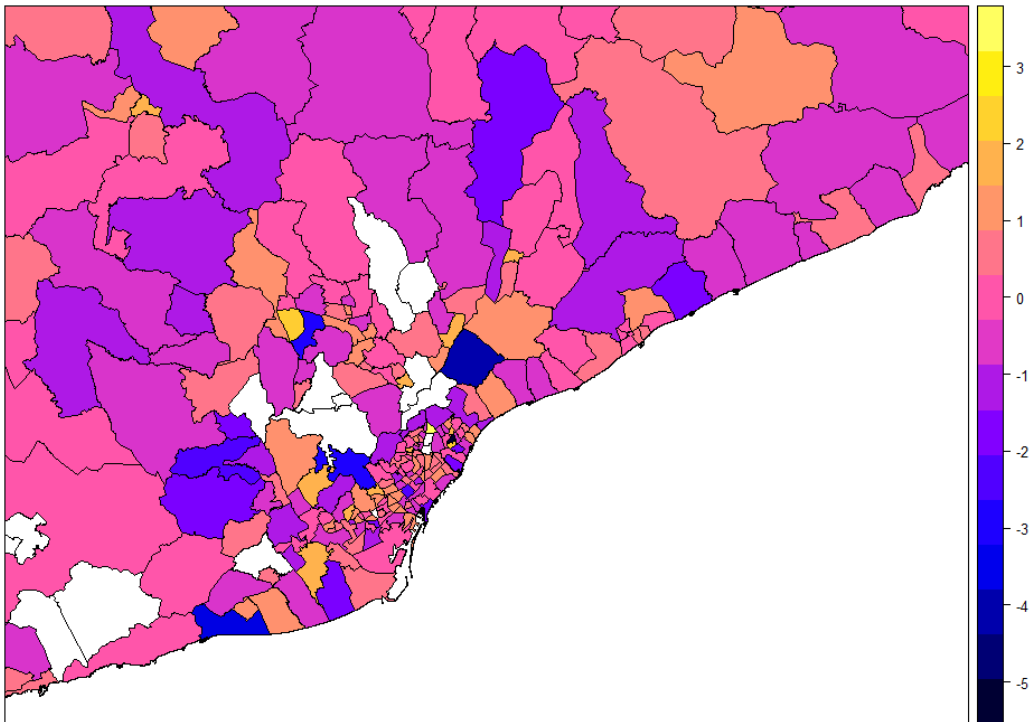


Figura 5.9 Residus model 4 Homes





Figura 5.10 Residus model 4 Homes



6.CONCLUSIONS

- El model que millor s'ajusta a les dades és el model 4, que té en compte tant l'índex de privació com l'estructura espacial. És un model que ens permet fer estimacions robustes davant de la gran variabilitat que tenim pel fet de treballar amb àrees petites.
- El model 4 també ens permet donar estimacions d'aquelles ABS on el càlcul clàssic de l'EV no havia estat possible de fer per manca de dades en algun moment del període d'anàlisi.
- Interpretant el model 4 podem veure que el coeficient que multiplica l'índex de privació és negatiu pels dos sexes, però per homes és aproximadament 4 cops més gran. Això ens diu que el fet de viure en àrees amb nivell socioeconòmic més baix afecta en l'esperança de vida 4 cops més als homes que a les dones. Fent inferència podem concloure que millorant els índexs de privació de les ABS, fent que els valors de l'índex siguin més petits, milloraríem l'EV d'aquelles ABS.
- L'EV de les dones per al territori català és aproximadament 5-6 anys més gran que la dels homes.
- Pel model 4, en el cas de les dones, les ABS amb EV més alta es concentren a l'Alt Empordà i a zones de l'àrea metropolitana com als districtes de l'Eixample, Les Corts i Sarrià-Sant Gervasi. Les ABS amb EV més baixa es concentren a la zona composta per Baix Penedès, Garraf i Baix Llobregat i també al Tarragonès.
- Pel model 4, en el cas dels homes es veuen més diferències que en les dones, les ABS amb EV més alta es concentren a l'Alt Empordà, a la Ribera d'Ebre i a zones de l'àrea metropolitana com Sant Cugat i als districtes de Les Corts i Sarrià-Sant Gervasi. Les ABS amb EV més baixa es concentren a la zona composta per Baix Penedès, Alt Penedès i el Garraf, al Segrià, a la zona composta per l'Alt Maresme i la Selva, la zona composta per el Ripollès i el Berguedà i finalment al Tarragonès.

Bibliografía

Bivand, R.S., Pebesma, E., Gómez-Rubio, V. *Applied Spatial Data Analysis with R*. Springer 2008.



Jimeno, Franz. *Mapas con R. Ejemplo de un Mapa de las áreas sanitarias de Asturias*. Disponible a: <https://www.franzjimeno.es/index.php/8-blog/programacion/r/12-mapas-con-r>, consulta 12 de maig de 2018.

Thomas, A., Best, N., Lunn, D., Arnold, R. & Spiegelhalter, D. *GeoBUGS User Manual Version 1.2, September 2004*. Disponible a: <https://www.mrc-bsu.cam.ac.uk/wp-content/uploads/geobugs12manual.pdf>, consulta 7 de juny de 2018.


Internet Guide to R, *Defining Neighbors, Creating Weight Matrices*. Disponible a: <http://wlm.userweb.mwn.de/R/wlmRspma.htm>, consulta 24 d' abril de 2018.

Apèndix 1: Mapes amb etiqueta ABS


ABS




ABS




ABS




ABS



ABS



ABS



Apèndix 2: Taula sencera que relaciona el codi ABS amb el seu nom

ABS	NOMABS
1	1
2	2
3	3
4	4
5	5
6	7
7	8
8	9
9	10
10	11
11	12
12	13
13	14
14	15
15	16
16	17
17	18
18	19
19	20
20	21
21	22
22	23
23	24
24	25
25	27
26	28
27	29
28	30
29	31
30	32
31	33
32	34
33	35
34	36
35	38
36	39
37	40
38	41
39	42
40	43
41	44
42	45
43	46
44	47
45	48
46	49
47	50
48	51
49	52
50	53

51	54	Barcelona - 7D
52	55	Barcelona - 7E
53	56	Barcelona - 7F
54	57	Barcelona - 8A
55	58	Barcelona - 8B
56	59	Barcelona - 8C
57	60	Barcelona - 8D
58	61	Barcelona - 8E
59	62	Barcelona - 8F
60	63	Barcelona - 8G
61	64	Barcelona - 8H
62	65	Barcelona - 9A
63	67	Barcelona - 9C
64	69	Barcelona - 9E
65	70	Barcelona - 9F
66	71	Barcelona - 10A
67	72	Barcelona - 10B
68	73	Barcelona - 10C
69	74	Barcelona - 10D
70	75	Barcelona - 10E
71	76	Barcelona - 10F
72	77	Barcelona - 10G
73	78	Barcelona - 10H
74	79	Barcelona - 10I
75	80	Bàsca
76	81	Bellpuig
77	82	Berga
78	83	Besalú
79	84	La Bisbal d'Empordà
80	85	Blanes
81	86	Les Borges Blanques
82	87	Les Borges del Camp
83	88	Calaf
84	89	Caldes de Montbui
85	90	Calella
86	91	Cambrils
87	92	Camprodon
88	93	Canet de Mar
89	95	Cardedeu
90	96	Cardona
91	97	Castellar del Vallès
92	98	Montserrat
93	100	Cassà de la Selva
94	101	Celrà
95	102	Centelles
96	103	La Cerdanya
97	104	Cerdanyola del Vallès - 1
98	105	Cerdanyola del Vallès - 2
99	106	Cervera
100	107	Constantí
101	108	Cornellà de Llobregat - 1
102	109	Cornellà de Llobregat - 2
103	110	Cornellà de Llobregat - 3
104	111	Cornellà de Llobregat - 4
105	112	Cornudella de Montsant
106	113	Deltebre
107	114	L'Escaia
108	115	Esparraguera
109	116	Esplugues de Llobregat - 1

110	117	Esplugues de Llobregat - 2
111	118	Falset
112	119	Figueres
113	120	Flix
114	121	La Garriga
115	122	Gavà - 1
116	123	Gavà - 2
117	124	Girona - 1
118	125	Girona - 2
119	126	Girona - 3
120	127	Girona - 4
121	128	Baix Berguedà
122	129	La Granadella
123	130	Alt Berguedà
124	131	Anoia rural
125	133	La Jonquera
126	134	Llançà
127	135	Lleida - 1 Centre històric - Rambla de Ferran
128	136	Lleida - 2 Primer de Maig
129	137	Lleida - 3 Eixample
130	138	Lleida - 4 Balàfia - Pardinyes - Secà de Sant Pere
131	139	Lleida - 5 Cappont
132	140	Lleida - 6 Bordeta - Magraners
133	141	Lleida rural - 1 Nord
134	142	Lloret de Mar
135	143	Malgrat de Mar
136	144	Manlleu
137	145	Manresa - 1
138	146	Manresa - 2
139	147	Manresa - 3
140	148	Manresa - 4
141	149	Martorell
142	150	Martorelles
143	152	Mataró - 1
144	153	Mataró - 2
145	154	Mataró - 3
146	155	Mataró - 4
147	156	Mataró - 5
148	157	Mataró - 6
149	158	Mataró - 7
150	159	Moià
151	160	Molins de Rei
152	161	Pla d'Urgell
153	162	Montblanc
154	163	Mont-roig del Camp
155	164	Montornès - Montmeló
156	165	Móra la Nova - Móra d'Ebre
157	166	El Morell
158	167	Navàs - Balsareny
159	168	Olesa de Montserrat
160	169	Alt Urgell Sud
161	171	Olot
162	172	Palafrugell
163	173	Palamós
164	174	Pallars Sobirà
165	175	Parets del Vallès
166	176	Penedès rural
167	177	Peralada
168	178	L'Ametlla de Mar - El Perelló

169	179	La Pobla de Segur
170	180	Alta Ribagorça
171	181	Ponts
172	182	El Prat de Llobregat - 1
173	183	El Prat de Llobregat - 2
174	184	El Prat de Llobregat - 3
175	185	Lluçanès
176	186	Premià de Mar
177	187	Ripoll - Sant Joan de les Abadesses
178	188	Riudoms
179	189	Roses
180	190	Sabadell - 1A
181	191	Sabadell - 1B
182	192	Sabadell - 2
183	193	Sabadell - 3A
184	194	Sabadell - 3B
185	196	Sabadell - 5
186	197	Sabadell - 6
187	198	Sabadell - 7
188	199	Salt
189	200	Sallent
190	201	Sant Andreu de la Barca
191	202	Sant Boi de Llobregat - 1
192	203	Sant Boi de Llobregat - 2
193	204	Sant Boi de Llobregat - 3
194	205	Sant Boi de Llobregat - 4
195	206	Sant Carles de la Ràpita
196	207	Sant Celoni
197	208	Sant Feliu de Guixols
198	209	Sant Feliu de Llobregat - 1
199	210	Sant Feliu de Llobregat - 2
200	211	Navarres - Sant Fruitós de Bages
201	212	Sant Hipòlit de Voltregà
202	213	Sant Joan Despí - 1
203	214	Sant Joan Despí - 2
204	215	Sant Joan de Vilatorrada
205	216	Sant Just Desvern
206	217	Sant Quirze de Besora
207	218	Sant Sadurní d'Anoia
208	219	Sant Vicenç de Castellet
209	221	Santa Coloma de Farners
210	222	Santa Coloma de Gramenet - 1
211	223	Santa Coloma de Gramenet - 2
212	224	Santa Coloma de Gramenet - 3
213	225	Santa Coloma de Gramenet - 4
214	226	Santa Coloma de Gramenet - 5
215	228	Santa Coloma de Queralt
216	229	Santa Margarida de Montbui
217	230	Santa Perpètua de Mogoda
218	231	Sarrià de Ter
219	232	Seròs
220	233	La Seu d'Urgell
221	234	Sils - Vidreres - Maçanet de la Selva
222	235	Sitges
223	236	Solsonès
224	237	Súria
225	238	Santa Eugènia de Berga
226	239	Tarragona - 1
227	240	Tarragona - 2

228	241	Tarragona - 3
229	242	Tarragona - 4
230	243	Tarragona - 5
231	244	Tarragona - 6
232	245	Tàrrrega
233	246	Terra Alta
234	247	Terrassa - A
235	248	Terrassa - B
236	249	Terrassa - C
237	250	Terrassa - D
238	251	Terrassa - E
239	252	Terrassa - F
240	253	Tona
241	254	La Vall del Ges
242	255	Tortosa - 1 Est
243	256	Tortosa - 2 Oest
244	257	Torredembarra
245	258	Torroella de Montgrí
246	259	Trepç
247	260	Ulldecona
248	261	Vallirana
249	262	Alt Camp Est
250	263	Valls urbà
251	265	Viladecans - 1
252	266	Viladecans - 2
253	267	Vilafant
254	269	Vilanova del Camí
255	271	Vilassar de Mar
256	272	Badalona - 1
257	273	Badalona - 2
258	274	Badalona - 3
259	275	Badalona - 4
260	276	Badalona - 5
261	277	Badalona - 6
262	279	Badalona - 8
263	280	Badalona - 9
264	281	Badalona - 10
265	282	Badalona - 11
266	283	Badalona - 12
267	284	Granollers - 1 Oest
268	285	Granollers - 2 Nord
269	286	Granollers - 3 Centre Est
270	287	Granollers - 4 Sud
271	288	L'Hospitalet de Llobregat - 1 Centre
272	289	L'Hospitalet de Llobregat - 2 Sant Josep
273	290	L'Hospitalet de Llobregat - 3 Collblanc
274	291	L'Hospitalet de Llobregat - 4 Torrasa
275	292	L'Hospitalet de Llobregat - 5 Santa Eulàlia N
276	293	L'Hospitalet de Llobregat - 6 Santa Eulàlia S
277	294	L'Hospitalet de Llobregat - 7 Florida N.
278	295	L'Hospitalet de Llobregat - 8 Florida S.
279	296	L'Hospitalet de Llobregat - 9 Pubilla Casas
280	297	L'Hospitalet de Llobregat - 10 Can Serra
281	298	L'Hospitalet de Llobregat - 11 Gornal
282	299	L'Hospitalet de Llobregat - 12 Bellvitge
283	300	La Llagosta
284	303	Reus - 1
285	304	Reus - 2
286	305	Reus - 3

287	306	Reus - 4
288	307	Reus - 5
289	309	Rubi - 1
290	310	Rubi - 2
291	311	Sant Adrià de Besòs - 1
292	312	Sant Adrià de Besòs - 2
293	314	Baix Penedès - Interior
294	315	Vall del Tenes
295	316	Vilanova i la Geltrú - 1
296	317	Vilanova i la Geltrú - 2
297	319	Montgat
298	320	Barberà del Vallès
299	322	Ciutat Badia
300	324	vandellòs i l'Hospitalet de l'Infant
301	325	Pineda de Mar
302	326	Barcelona - 7G
303	327	Barcelona - 8I
304	328	L'Aldea - Camarles - l'Ampolla
305	329	Lleida rural - 2 Sud
306	330	Breda - Hostalric
307	331	Barcelona - 10J
308	333	Alt Camp Oest
309	334	Almacelles
310	335	Sant Andreu de Llavaneres
311	336	Tordera
312	337	Capellades
313	338	Piera
314	339	Salou
315	340	Vila-seca
316	341	Badalona - 7A
317	342	Badalona - 7B
318	343	Ribes de Freser - Campdevànol
319	344	Sabadell - 4A
320	345	Sabadell - 4B
321	346	Sant Joan les Fonts
322	347	La Vall d'en Bas
323	348	Mollet del Vallès - 1 Est
324	349	Mollet del Vallès - 2 Oest
325	350	Vic - 1 Nord
326	351	Vic - 2 Sud
327	352	Tarragona - 7 Sant Salvador
328	353	Vilassar de Dalt
329	354	La Selva del Camp
330	355	La Roca del Vallès
331	356	Terrassa - G
332	357	Calafell
333	358	Barcelona - 6E
334	359	Cubelles - Cunit
335	360	Martorell rural
336	361	El Masnou - Alella
337	362	Ocata - Teià
338	363	Sant Quirze del Vallès
339	364	Tarragona - 8
340	365	Castelldefels - 1
341	366	Castelldefels - 2
342	367	Pallejà
343	368	Santa Coloma de Gramenet - 6
344	369	Corbera de Llobregat
345	370	Abrera

346	371	Igualada - 1
347	372	Igualada - 2
348	373	Begues
349	374	Sant Vicenç dels Horts - 1
350	375	Sant Vicenç dels Horts - 2
351	376	Alt Mogent
352	377	Roda de Ter
353	378	Rubí - 3
354	379	Lleida - 7 Onze de Setembre
355	380	Vilanova i la Geltrú - 3
356	381	Montcada i Reixac - 1
357	382	Montcada i Reixac - 2
358	383	Barcelona - 3H
359	384	Cerdanyola - Ripollet
360	385	Barcelona - 8J
361	386	Ripollet - 1
362	387	Ripollet - 2
363	388	Sant Cugat del Vallès - 1
364	389	Sant Cugat del Vallès - 2
365	390	Sant Cugat del Vallès - 3
366	391	Palau-solità i Plegamans
367	392	Polinyà - Sentmenat
368	393	Ribes - Olivella
369	394	Roquetes - Canyelles
370	395	Barcelona - 9H
371	396	Barcelona - 9I
372	397	Vilafranca del Penedès - 1
373	398	Vilafranca del Penedès - 2
374	399	Castellbisbal
375	400	Barcelona - 3I
376	401	Viladecans - 3

Apèndix 3: Taula de districtes

2. Districtes

Districtes

BARCELONA

1. Ciutat Vella
2. Eixample
3. Sants-Montjuïc
4. Les Corts
5. Sarrià-Sant Gervasi
6. Gràcia
7. Horta-Guinardó
8. Nou Barris
9. Sant Andreu
10. Sant Martí

Font: Lectura del Padró Municipal d'Habitants a 1 gener 2017. Departament d'Estadística. Ajuntament de Barcelona.

Apèndix 4: Funció per calcular l'EV amb codi R

```
evida<-function(ax,d,p,nx){  
  
  n<-length(ax)  
  
  mx<-d/p  
  
  qx <- (nx * mx)/(1 + (1-ax) * nx *mx)  
  
  qx <- c(qx[-(length(qx))], 1) ## canviem el valor de l'ultim grup  
  
  l0<-100000  
  
  px<-1-qx  
  
  lx <- cumprod(c(l0, px))  
  
  dx <- -diff(lx)  
  
  lx<-lx[-length(lx)] ## eliminem l'ultim valor  
  
  Lx<-(nx*(lx-(1-ax)*dx))  
  
  Lx <- c(Lx[-(length(Lx))], (lx[length(lx)]/mx[length(mx)]))  
  
  Tx <- c(rev(cumsum(rev(Lx)))) ## fa la suma acumulada del vector al revés  
  
  ex<-Tx/lx  
  
  #return(list(mx=mx,qx=qx,lx=lx,dx=dx,Lx=Lx,Tx=Tx,ex=ex,e0=ex[1]))  
  
  return(e0=ex[1])  
  
}
```

Apèndix 5: Codi Models WINBUGS

Model 1:

```
model{  
  
  for(i in 1:n) {  
  
    y[i] ~ dnorm(mu, tau)  
  
  }  
  
}
```

```

mu ~ dnorm(80, 0.01)
tau <- 1/(sigma*sigma)
sigma ~ dunif(0,10)
}

```

Model 2:

```

model{
  for(i in 1:n) {
    y[i] ~ dnorm(mu[i], tau)
    mu[i] <- a0 + a1 * X[i]
  }
  a0 ~ dnorm(80, 0.01)
  a1 ~ dnorm(1, 0.01)
  tau <- 1/(sigma*sigma)
  sigma ~ dunif(0,10)
}

```

Model 3:

```

model{
  for(i in 1:n) {
    y[i] ~ dnorm(mu[i], tau)
    mu[i] <- a0 + b[i]
  }
  # CAR prior distribution for random effects:
  b[1:n] ~ car.normal(adj[], weights[], num[], tau.b)
  for(k in 1:sumNumNeigh) {
    weights[k] <- 1
  }
}

```

```

}
a0 ~ dnorm(80, 0.01)
tau <- 1/(sigma*sigma)
sigma ~ dunif(0,10)
tau.b <- 1/(sigma.b*sigma.b)
sigma.b ~ dunif(0,10)
}

```

Model 4:

```

model{
  for(i in 1:n) {
    y[i] ~ dnorm(mu[i], tau)
    mu[i] <- a0 + b[i] + c * X[i]
  }
  # CAR prior distribution for random effects:
  b[1:n] ~ car.normal(adj[], weights[], num[], tau.b)
  for(k in 1:sumNumNeigh) {
    weights[k] <- 1
  }
  a0 ~ dnorm(80, 0.01)
  c ~ dnorm(0,0.01)
  tau <- 1/(sigma*sigma)
  sigma ~ dunif(0,10)
  tau.b <- 1/(sigma.b*sigma.b)
  sigma.b ~ dunif(0,10)
}

```


Apèndix 6: Codi R complet

```
### Importació de dades ###

### Defuncions

### El fitxer de defuncions s'ha de passar a csv ja que sino no es llegeixen bé els espais

defuncions<-read.csv2("G:/TFG/fitxers a enviar/Def_2011-2015_ABS_PFG4.csv",header =
FALSE,sep=";")
colnames(defuncions)<-
c("sexe","grupedat","etiqrupedat","grupcausa","etiqrupcausa","abs","numseqencial")
defuncions

poblacio<-read.table("G:/TFG/fitxers a enviar/Població_2011-2015_ABS.txt",header = FALSE,sep="")
colnames(poblacio)<-c("abs","sexe","grupedat","etiqrupedat","nombrepoblacio")
poblacio

ax<-read.csv2("G:/ax.csv",header = FALSE,sep = "\t")
axdones<-ax[,1]
axhomes<-ax[,2]
nx<-c(1,4,rep(5,18))
nx
### és el que em faltava canviar, és la longitud del grup
poblaciohomes<-subset(poblacio,subset = sexe==1)
poblaciodones<-subset(poblacio,subset = sexe==6)

defuncionshomes<-subset(defuncions,subset = sexe==1,select = c(1,2,3,6))
defuncionsdones<-subset(defuncions,subset = sexe==6,select = c(1,2,3,6))

table(defuncionsdones$abs,defuncionsdones$grupedat)
table(defuncionshomes$abs,defuncionshomes$grupedat)

defuncionsdonesdef<-data.frame(table(defuncionsdones$abs,defuncionsdones$grupedat))
colnames(defuncionsdonesdef)<-c("abs","grupedat","nombredefuncions")

defuncionshomesdef<-data.frame(table(defuncionshomes$abs,defuncionshomes$grupedat))
colnames(defuncionshomesdef)<-c("abs","grupedat","nombredefuncions")

abspob<-unique(poblacio$abs)
length(abspob)
absdef<-unique(defuncions$abs)
length(absdef)

setdiff(absdef,abspob)
sensedefs<-setdiff(abspob,absdef)
absdef<-sort(absdef)
#### veure quines son les abs diferents de defuncions i poblacions
```

```
#### calcul esperança de vida
```

```
evida<-function(ax,d,p,nx){  
  n<-length(ax)  
  mx<-d/p  
  qx <- (nx * mx)/(1 + (1-ax) * nx *mx)  
  qx <- c(qx[-(length(qx))], 1) ## canviem el valor de l'ultim grup  
  l0<-100000  
  px<-1-qx  
  lx <- cumprod(c(l0, px))  
  dx <- -diff(lx)  
  lx<-lx[-length(lx)] ## eliminem l'ultim valor  
  Lx<-(nx*(lx-(1-ax)*dx))  
  Lx <- c(Lx[-(length(Lx))], (lx[length(lx)]/mx[length(mx)]))  
  Tx <- c(rev(cumsum(rev(Lx)))) ## fa la suma acumulada del vector al revés  
  ex<-Tx/lx  
  #return(list(mx=mx,qx=qx,lx=lx,dx=dx,Lx=Lx,Tx=Tx,ex=ex,e0=ex[1]))  
  return(e0=ex[1])  
}
```

```
##calcul ev global cat
```

```
defhcat<-  
aggregate(defuncionshomesdef$nombredefuncions,by=list(defuncionshomesdef$grupedat),FUN=sum)  
pobhcat<-aggregate(poblaciohomes$nombrepoblacio,by=list(poblaciohomes$grupedat),FUN=sum)  
e0hcat<-evida(axhomes,defhcat[,2],pobhcat[,2],nx)  
e0hcat  
defdcat<-  
aggregate(defuncionsdonesdef$nombredefuncions,by=list(defuncionsdonesdef$grupedat),FUN=sum)  
pobdcat<-aggregate(poblacioidones$nombrepoblacio,by=list(poblacioidones$grupedat),FUN=sum)  
e0dcat<-evida(axhomes,defdcat[,2],pobdcat[,2],nx)  
e0dcat
```

```
## agreguem defuncions per cada abs
```

```
defhxabs<-  
aggregate(defuncionshomesdef$nombredefuncions,by=list(defuncionshomesdef$abs),FUN=sum)  
defdxabs<-  
aggregate(defuncionsdonesdef$nombredefuncions,by=list(defuncionsdonesdef$abs),FUN=sum)  
hist(defdxabs$x,breaks = 20,main="Nombre defuncions dones per cada ABS (2011-2015)",col =  
"green")  
hist(defhxabs$x,breaks = 20,main="Nombre defuncions homes per cada ABS (2011-  
2015)",col="green")  
## agreguem poblacions per cada abs  
pobhxabs<-aggregate(poblaciohomes$nombrepoblacio,by=list(poblaciohomes$abs),FUN=sum)  
pobdxabs<-aggregate(poblacioidones$nombrepoblacio,by=list(poblacioidones$abs),FUN=sum)
```

```

hist(pobdxabs$x,breaks = 20,main="Nombre població dones per cada ABS (2011-2015)",col = "blue")
hist(pobhxabs$x,breaks = 20,main="Nombre població homes per cada ABS (2011-2015)",col="blue")

##### càlcul no correcte1
#defdcat$puntmig<-c(0,seq(2.5,97.5,5))
#vidamitjanad<-sum((defdcat$x*defdcat$puntmig)/sum(defdcat$x))
#vidamitjanad
#defhcat$puntmig<-c(0,seq(2.5,97.5,5))
#vidamitjanah<-sum((defhcat$x*defhcat$puntmig)/sum(defhcat$x))
#vidamitjanah
## calcul no correcte 2
#pobdcat$puntmig<-c(0,seq(2.5,97.5,5))
#vidamitjanad2<-sum((pobdcat$x*pobdcat$puntmig)/sum(pobdcat$x))
#vidamitjanad2
#pobhcat$puntmig<-c(0,seq(2.5,97.5,5))
#vidamitjanah2<-sum((pobhcat$x*pobhcat$puntmig)/sum(pobhcat$x))
#vidamitjanah2
#####
vecabsh<-vector(length=length(absdef))
vece0h<-vector(length=length(absdef))
#calcul evida homes
for (i in absdef){
  e0<-evida(axhomes,defuncionshomesdef$nombredefuncions[defuncionshomesdef$abs==i],
            poblaciohomes$nombrepoblacio[poblaciohomes$abs==i],nx)
  vecabsh[i]<-i
  vece0h[i]<-e0
}

vecabsh
vece0h

evh<-data.frame(abs=vecabsh,e0=vece0h)
#####

vecabsd<-vector(length=length(absdef))
vece0d<-vector(length=length(absdef))
#calcul evida dones
for (i in absdef){
  e0<-evida(axdones,defuncionsdonesdef$nombredefuncions[defuncionsdonesdef$abs==i],
            poblaciodones$nombrepoblacio[poblaciodones$abs==i],nx)
  vecabsd[i]<-i
  vece0d[i]<-e0
}

vecabsd
vece0d

evd<-data.frame(abs=vecabsd,e0=vece0d)

```

```

write.csv(evh,file="evidahomes.csv")
write.csv(evd,file="evidadones.csv")

## guardarem Rdata del càlcul cru de l'esperança de vida
save(evh,evd,file="G:/evidasensecanvis.RData")

#### fins aquí tenim el càlcul clàssic de l'esperança de vida,
# ara farem la neteja de la base de dades, càlcul per esperances de vida d'abs noves

##! ABS 379 se'ls adjudiquin a les ABS 135, 137 i 138

evd[135,1]<-135
evd[135,2]<-evd[379,2]
evd[137,1]<-137
evd[137,2]<-evd[379,2]
evd[138,1]<-138
evd[138,2]<-evd[379,2]

evh[135,1]<-135
evh[135,2]<-evh[379,2]
evh[137,1]<-137
evh[137,2]<-evh[379,2]
evh[138,1]<-138
evh[138,2]<-evh[379,2]

#### ara eliminarem les files del df sense abs que no són cap abs, exemple abs 6
evddef<-subset(evd,subset = evd$e0!=0)
evhdef<-subset(evh,subset = evh$e0!=0)

## ABS que al començament hi eren i ara no
#o viceversa això fa que hi hagi una manca de dades en alguns anys concrets
## les marcarem amb un NA potser d'ha marcar amb 0
evddef[364,2]<-NA
evddef[365,2]<-NA
evddef[366,2]<-NA
evddef[367,2]<-NA
evddef[368,2]<-NA
evddef[369,2]<-NA
evddef[370,2]<-NA
evhdef[364,2]<-NA
evhdef[365,2]<-NA
evhdef[366,2]<-NA
evhdef[367,2]<-NA
evhdef[368,2]<-NA
evhdef[369,2]<-NA
evhdef[370,2]<-NA

write.csv(evhdef,file="evidahomesdef.csv")
write.csv(evddef,file="evidadonesdef.csv")

```

```

save(evh,evhdef,evd,evddef,file="G:/evida.RData")

hist(evhdef$e0,main = "Histograma EV Homes per ABS ",xlim = c(74,86),col=2)
hist(evddef$e0,main = "Histograma EV Dones per ABS ",col=2)

#### Creació matriu de veinatge

library(mapttools)
library(rgdal)
library(sf)
#gpclibPermit()

##prova comarca
#MapCom1 <- readShapePoly("G:/comarca/comarca.shp")
#plot(MapCom1)
#plot(MapCom1 , col=c(rep("blue",20),rep("yellow",21)))

#MapCom <- readOGR("G:/comarca/comarca.shp")
#MapCom2 <- st_read("G:/comarca/comarca.shp")
#plot(MapCom)
#plot(MapCom , col=c(rep("blue",20),rep("yellow",21)))
#plot(MapCom2)
#plot(MapCom2 , col=c(rep("blue",20),rep("yellow",21)))

##prova abs

gpclibPermit()
MapABS<-readShapePoly("G:/2017_ABS/ABS_2017.shp")
plot(MapABS)
plot(MapABS , col=c(rep("blue",20),rep("yellow",21)))

###
#gpclibPermit()
#MapABSnova<-readShapePoly("G:/formats mapes/Shape_ESRI/ABS_2017.shp")
#plot(MapABSnova)
## Creació matriu de veinatges

library(spdep)
veinatges<-poly2nb(MapABS)
matveinatges<-nb2WB(veinatges)
nb.a <- matveinatges[1]
nb.w <- matveinatges[2]
nb.n <- matveinatges[3]
adjb <- dput(nb.a,control=NULL)
weightb <- dput(nb.w,control=NULL)
numb <- dput(nb.n,control=NULL)

```

```

## importació index privació
#iprivacio<-read.csv2("clipboard",header=T,sep="\t") # manera importar dades
#save(iprivacio,file="G:/indexprivacio.RData")
load("G:/indexprivacio.RData")
hist(iprivacio$valor.ABS.total,main = "Índex de privació",col="yellow")
colnames(iprivacio)[1]<-"CODIABSNUM"
MapABS@data$CODIABSNUM<-as.numeric(paste(MapABS@data$CODIABS))
setdiff(MapABS@data$CODIABSNUM,iprivacio$CODIABSNUM)
setdiff(iprivacio$CODIABSNUM,MapABS@data$CODIABSNUM)
newi<-
data.frame(CODIABSNUM=c(36,38,149,265,266,399,382,381,393,394,400,398,401,397),ABS=NA,RS=
NA,
          valor.ABS.total=c(2.17,1.42,2.8,2.68,3.22,NA,NA,NA,NA,NA,NA,NA,NA,NA))
iprivacio<-rbind(iprivacio,newi)
iprivacio<-iprivacio[order(iprivacio$CODIABSNUM),]

#library(sp)
#spplot(MapABS,"CODIAGA") ## no es això però per veure que necessito la variable dintre de
l'objecte
#MapABS@data$iprivacio<-iprivacio$valor.ABS.total
MapABS@data$CODIABSNUM<-as.numeric(paste(MapABS@data$CODIABS))

#### VEURE LES DIFERÈNCIES DE ABS ELEMENTS DEL PRIMER QUE NO SÓN AL SEGON
setdiff(evhdef$abs,MapABS@data$CODIABSNUM)
setdiff(MapABS@data$CODIABSNUM,evhdef$abs)

#eliminació abs que s'han disgregat
evhdef<-evhdef[-c(254,285,299),]
evddef<-evddef[-c(254,285,299),]

newh<-data.frame(abs=c(399,382,381,393,394,400,398,401,391),e0=NA)

evhdef<-rbind(evhdef,newh)
evddef<-rbind(evddef,newh)
## afegim abs que s'han creat noves

write.csv(evhdef,file="evidahomesdef2.csv")
write.csv(evddef,file="evidadonesdef2.csv")
write.csv(iprivacio,file = "iprivaciodef.csv")

save(evh,evhdef,evd,evddef,file="G:/evidadef.RData")
#Creació mapes
sp.label <- function(x, label) {
  list("sp.text", coordinates(x), label,cex=0.5,col="white")
}

```

```

}

NAME.sp.label <- function(x) {
  sp.label(x, x@data$CODIABSNUM)
}

draw.sp.label <- function(x) {
  do.call("list", NAME.sp.label(x))
}

merged <- merge(MapABS@data,iprivacio,all=T)
correct.ordering <- match(MapABS$CODIABSNUM, merged$CODIABSNUM)

MapABS@data$valor <- merged$valor.ABS.total[correct.ordering]
spplot(MapABS,"valor",main="Índex de privació")
#spplot(MapABS,"valor",main="Índex de privació",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
#spplot(MapABS,"valor",main="Índex de privació",xlim = c( 435766,486555.1),ylim =
c(4580500.7,4631532))
spplot(MapABS,"valor",main="Índex de privació",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

## IMPORTACIÓ EVIDES
load("G:/evidadef.RData")

colnames(evhdef)[1]<-"CODIABSNUM"
colnames(evddef)[1]<-"CODIABSNUM"
merged2 <- merge(MapABS@data,evhdef,all=T)
correct.ordering2 <- match(MapABS$CODIABSNUM, merged2$CODIABSNUM)

MapABS@data$e0h <- merged2$e0[correct.ordering2]
spplot(MapABS,"e0h",main="Esperança de vida homes")## mapa esperança vida homes
#spplot(MapABS,"e0h",main="Esperança de vida homes",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"e0h",main="Esperança de vida homes",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

merged3 <- merge(MapABS@data,evddef,all=T)
correct.ordering3 <- match(MapABS$CODIABSNUM, merged3$CODIABSNUM)

MapABS@data$e0d <- merged3$e0[correct.ordering3]
spplot(MapABS,"e0d",main="Esperança de vida dones")## mapa esperança vida dones
#spplot(MapABS,"e0d",main="Esperança de vida dones",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"e0d",main="Esperança de vida dones",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

save(evddef,evhdef,iprivacio,file="dadesmodelsespacials.RData")

```

```

##Models espacials

load("G:/objectesmatriuveinatges.RData")
load("G:/dadesmodelsespacials.RData")

path.bug <- "G:/modelswinbugs/"
#path.WBs <- "C:/Program Files/WinBUGS14/"
path.WBs<-"C:/Users/MARC/Downloads/winbugs14_unrestricted (2)/WinBUGS14"
Iter <- 5000
Burn <- 2000
Thin <- 5
Chain <- 2

### en llença "Burn", i despres se'n queda "Iter" que les tria cada "Thins", es a dir en simmula
Burn+Iter*Thin per
### a cada cadena, nombre de cadenes es "Chain"

# primer instal·lar les llibreries coda i R2WinBUGS

library(R2WinBUGS)
#####
mglobal<-mean(iprivacio$valor.ABS.total,na.rm=T)
mglobal
iprivacio2<-iprivacio
# per a crear els models la variable indexprivació no ha de tenir missings així que anem a importar-los
iprivacio2[374,4]<-2.8 ## prove de la abs 149
iprivacio2[357,4]<-3.14
iprivacio2[356,4]<-3.14
iprivacio2[368,4]<-2.32
iprivacio2[369,4]<-2.32
iprivacio2[375,4]<-(2.17+1.42)/2 ##mitjana dels 2 indexs de privacio d'on prove
iprivacio2[373,4]<-2.69
iprivacio2[372,4]<-2.69
iprivacio2[376,4]<-(2.68+3.22)/2
iprivacio2[6,4]<-(mglobal+mean(iprivacio2[164,4],iprivacio2[170,4]))/2
#iprivacio2[354,4]<-
(mglobal+(mean(iprivacio2[2,4],iprivacio2[127,4],iprivacio2[129,4],iprivacio2[133,4],iprivacio2[130,4],
,iprivacio2[309,4])))/2#no dona
iprivacio2[354,4]<-(mglobal+(sum(3.06,2.92,1.79,2.29,3.16,2.61)/6))/2
## aquests ip són prediccions a partir de les abs d'on venen,
## les següents tenen a veure amb la mitjana global i la mitjana dels veïns
## passem l'objecte al mapa

merged4 <- merge(MapABS@data,iprivacio2,all=T)
correct.ordering4 <- match(MapABS$CODIABSNUM, merged4$CODIABSNUM)

MapABS@data$valor2 <- merged4$valor.ABS.total[correct.ordering4]
spplot(MapABS,"valor2",main="Índex de privació amb imputacions")

```



```

#spplot(MapABS,"valor2",main="Índex de privació amb imputacions",xlim = c( 390000, 441766),ylim
= c(4559500.7,4611532))
spplot(MapABS,"valor2",main="Índex de privació amb imputacions",xlim = c( 390000,486555.1),ylim
= c(4559500.7,4631532))

#####
n<-length(MapABS@data[["e0d"]])
## Model 1: EV~Normal(mu,sigma)

##### MODEL 1 dones #####

dades <- list(n=length(MapABS@data[["e0d"]]), y = MapABS@data[["e0d"]])

inicials <- list(list(mu= 80, sigma= 3),list(mu= 90, sigma= 6))

parametres <- c("mu", "sigma", "y")

model1d <- bugs(dades, inicials, parameters.to.save=parametres,
              model=paste(path.bug,"model1h.bug",sep=""),
              bugs.directory=path.WBs,
              n.iter=(lter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE,
              DIC=TRUE)
### cal esperar estona
print(model1d , digits=6 )
summary(model1d)

DICm1d<-model1d$DIC
attach.bugs(model1d)

#mu
MapABS@data$evdmodel1 <- mean(mu)
spplot(MapABS,"evdmodel1",main="Model 1 EVD")
#spplot(MapABS,"evdmodel1",main="Model 1 EVD",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evdmodel1",main="Model 1 EVD",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
## a part farem gràfics per veure on és cada abs
spplot(MapABS,"evdmodel1",main="ABS",sp.layout=draw.sp.label(MapABS))
spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 400000, 441766),ylim =
c(4569500.7,4621532),sp.layout=draw.sp.label(MapABS))
spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 420000, 441766),ylim =
c(4569500.7,4600532),sp.layout=draw.sp.label(MapABS))
spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 441766,526555.1),ylim =
c(4609500.7,4711532),sp.layout=draw.sp.label(MapABS))
spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 261766,366555.1),ylim =
c(4489500.7,4581532),sp.layout=draw.sp.label(MapABS))

```

```

spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 281766,367555.1),ylim =
c(4599500.7,4701532),sp.layout=draw.sp.label(MapABS))
spplot(MapABS,"evdmodel1",main="ABS",xlim = c( 435766,486555.1),ylim =
c(4580500.7,4631532),sp.layout=draw.sp.label(MapABS))
#### mostrarem cada abs on és

## es crea el dataframe per saber quin ABS representa cada territori
#d1<-data.frame(nom=MapABS@data[["NOMABS"]],idabsss=MapABS@data$CODIABSNUM)
#d2<-d1[order(d1$idabsss),]
#d2
#d3<-data.frame(ABS=d2$idabsss,NOMABS=d2$nom)
#d3
###

par(mfrow=c(2,1))

plot(density(mu, adjust = 1.5), main = expression(paste(pi,"(",mu,"|y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma,"|y)")), xlab= "" )

detach.bugs()

### MODEL 1 homes##
dades <- list(n=length(MapABS@data[["e0h"]]), y = MapABS@data[["e0h"]])

inicials <- list(list(mu= 75, sigma= 3),list(mu= 85, sigma= 6))

parametres <- c("mu", "sigma", "y")

model1h <- bugs(dades, inicials, parameters.to.save=parametres,
               model=paste(path.bug,"model1h.bug",sep=""),
               bugs.directory=path.WBs,
               n.iter=(lter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)
### cal esperar estona
print(model1h , digits=6 )
summary(model1h)
DICm1h<-model1h$DIC

attach.bugs(model1h)

MapABS@data$evhmodel1 <- mean(mu)
spplot(MapABS,"evhmodel1",main="Model 1 EVH")
#spplot(MapABS,"evhmodel1",main="Model 1 EVH",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evhmodel1",main="Model 1 EVH",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(2,1))

```

```

plot(density(mu, adjust = 1.5), main = expression(paste(pi, "(", mu, " | y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi, "(", sigma, " | y)")), xlab= "" )

detach.bugs()
#####

## Model 3: EV~Normal(mu,sigma), mu~normal(mubarra,sigma) mubarra=mitjanade mus veines

##### MODEL 3 DONES #####

dades <- list(n=length(MapABS@data[["e0d"]]), y = MapABS@data[["e0d"]], num=num, adj=adj,
sumNumNeigh=sum(num))

inicials <- list(list(a0= 80, sigma= 3, sigma.b = 4, b=rep(0,n)),
list(a0= 90, sigma= 6, sigma.b = 2, b=rep(0,n)))

parametres <- c("y", "a0", "sigma", "sigma.b", "mu", "b")

## posar a i b paràmetres costa molt

model3d <- bugs(dades, inicials, parameters.to.save=parametres,
model=paste(path.bug,"model3hNOU.bug",sep=""),
bugs.directory=path.WBs,
n.iter=(Iter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)

print(model3d , digits=6 )
summary(model3d)
DICm3d<-model3d$DIC

attach.bugs(model3d)

MapABS@data$evdmodel3 <- apply(mu,2,mean)
spplot(MapABS,"evdmodel3",main="Model 3 EVD")
#spplot(MapABS,"evdmodel3",main="Model 3 EVD",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evdmodel3",main="Model 3 EVD",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

```

```

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0," | y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma," | y)")), xlab= "" )
plot(density(sigma.b, adjust = 1.5), main = expression(paste(pi,"(",sigma.b," | y)")), xlab= "" )
detach.bugs()

##### MODEL 3 HOMES #####

dades <- list(n=length(MapABS@data[["e0h"]]), y = MapABS@data[["e0h"]], num=num, adj=adj,
sumNumNeigh=sum(num))

iniciais <- list(list(a0= 70, sigma= 3, sigma.b = 4, b=rep(0,n)),
list(a0= 85, sigma= 6, sigma.b = 2, b=rep(0,n)))

parametres <- c("y", "a0", "sigma", "sigma.b","mu","b")

model3h <- bugs(dades, iniciais, parameters.to.save=parametres,
model=paste(path.bug,"model3hNOU.bug",sep=""),
bugs.directory=path.WBs,
n.iter=(lter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)

print(model3h , digits=6 )
summary(model3h)
DICm3h<-model3h$DIC

attach.bugs(model3h)

MapABS@data$evhmodel3 <- apply(mu,2,mean)
spplot(MapABS,"evhmodel3",main="Model 3 EVH")
#spplot(MapABS,"evhmodel3",main="Model 3 EVH",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evhmodel3",main="Model 3 EVH",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0," | y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma," | y)")), xlab= "" )

```

```

plot(density(sigma.b, adjust = 1.5), main = expression(paste(pi,"(",sigma.b,"|y)")), xlab= "" )
detach.bugs()

#####

## MODEL 2 yi~Normal(beta0+beta1*IP,sigma) # no funciona

##### MODEL 2 dones #####

summary(iprivacio2$valor.ABS.total)
dades <- list(n=length(MapABS@data[["e0d"]]), y = MapABS@data[["e0d"]],
X=MapABS@data[["valor2"]])
#dades <- list(n=5, y = evddef$e0[1:5], X=iprivacio$valor.ABS.total[1:5])

inicials <- list(list(a0= 80, a1=0, sigma= 3),list(a0= 90,a1=1, sigma= 6))

parametres <- c("a0","a1", "sigma", "y","mu")
#parametres <- c("a0","a1", "sigma","mu")

model2d <- bugs(dades, inicials, parameters.to.save=parametres,
               model=paste(path.bug,"model2h.bug",sep=""),
               bugs.directory=path.WBs,
               n.iter=(Iter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)
### cal esperar estona
print(model2d , digits=6 )
summary(model2d)
DICm2d<-model2d$DIC

attach.bugs(model2d)

MapABS@data$evdmodel2 <- apply(mu,2,mean)
spplot(MapABS,"evdmodel2",main="Model 2 EVD")
#spplot(MapABS,"evdmodel2",main="Model 2 EVD",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evdmodel2",main="Model 2 EVD",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0,"|y)")), xlab= "" )
plot(density(a1, adjust = 1.5), main = expression(paste(pi,"(",a1,"|y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma,"|y)")), xlab= "" )

detach.bugs()

#####
## model 2 homes

```

```

dades <- list(n=length(MapABS@data[["e0h"]]), y = MapABS@data[["e0h"]],
X=MapABS@data[["valor2"]])
#dades <- list(n=5, y = evddef$e0[1:5], X=iprivacio$valor.ABS.total[1:5])

iniciais <- list(list(a0= 70, a1=0, sigma= 3),list(a0= 85,a1=1, sigma= 6))

parametres <- c("a0","a1", "sigma", "y","mu")
#parametres <- c("a0","a1", "sigma","mu")

model2h <- bugs(dades, iniciais, parameters.to.save=parametres,
               model=paste(path.bug,"model2h.bug",sep=""),
               bugs.directory=path.WBs,
               n.iter=(Iter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)
### cal esperar estona
print(model2h , digits=6 )
summary(model2h)
DICm2h<-model2h$DIC

attach.bugs(model2h)

MapABS@data$evhmodel2 <- apply(mu,2,mean)
spplot(MapABS,"evhmodel2",main="Model 2 EVH")
#spplot(MapABS,"evhmodel2",main="Model 2 EVH",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evhmodel2",main="Model 2 EVH",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0," | y)")), xlab= "" )
plot(density(a1, adjust = 1.5), main = expression(paste(pi,"(",a1," | y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma," | y)")), xlab= "" )

detach.bugs()

#####
##### MODEL 4 dones #####

dades <- list(n=length(MapABS@data[["e0d"]]), y = MapABS@data[["e0d"]],
X=MapABS@data[["valor2"]],
             num=num, adj=adj, sumNumNeigh=sum(num))
#dades <- list(n=5, y = evhdef$e0[1:5],X=iprivacio$valor.ABS.total[1:5],
#num=num[1:5], adj=adj[1:22], sumNumNeigh=sum(num[1:5]))

iniciais <- list(list(a0= 80,c=0, sigma= 3, sigma.b = 4, b=rep(0,n)),

```

```

list(a0= 90,c=1, sigma= 6, sigma.b = 2, b=rep(0,n)))

parametres <- c("y", "a0", "sigma", "sigma.b","c","mu","b")
#parametres <- c( "a0", "sigma", "sigma.a", "sigma.b", "c")

model4d <- bugs(dades, iniciales, parameters.to.save=parametres,
               model=paste(path.bug,"model4hNOU.bug",sep=""),
               bugs.directory=path.WBs,
               n.iter=(lter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)

print(model4d , digits=6 )
summary(model4d)
DICm4d<-model4d$DIC

attach.bugs(model4d)

MapABS@data$evdmodel4 <- apply(mu,2,mean)
spplot(MapABS,"evdmodel4",main="Model 4 EVD")
#spplot(MapABS,"evdmodel4",main="Model 4 EVD",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evdmodel4",main="Model 4 EVD",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0," | y)")), xlab= "" )
plot(density(c, adjust = 1.5), main = expression(paste(pi,"(",c," | y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma," | y)")), xlab= "" )
plot(density(sigma.b, adjust = 1.5), main = expression(paste(pi,"(",sigma.b," | y)")), xlab= "" )
detach.bugs()

#####
##### MODEL 4 homes #####

dades <- list(n=length(MapABS@data[["e0h"]]), y = MapABS@data[["e0h"]],
             X=MapABS@data[["valor2"]],
             num=num, adj=adj, sumNumNeigh=sum(num))
#dades <- list(n=5, y = evhdef$e0[1:5],X=iprivacio$valor.ABS.total[1:5],
#num=num[1:5], adj=adj[1:22], sumNumNeigh=sum(num[1:5]))

iniciales <- list(list(a0= 70,c=0, sigma= 3, sigma.b = 4, b=rep(0,n)),
                 list(a0= 85,c=1, sigma= 6, sigma.b = 2, b=rep(0,n)))

```

```

parametres <- c("y", "a0", "sigma", "sigma.b", "c", "mu")
#parametres <- c("a0", "sigma", "sigma.a", "sigma.b", "c")

model4h <- bugs(dades, inicials, parameters.to.save=parametres,
               model=paste(path.bug,"model4hNOU.bug",sep=""),
               bugs.directory=path.WBs,
               n.iter=(Iter*Thin+Burn),n.burnin=Burn, n.thin=Thin, n.chains=Chain, debug=TRUE, DIC=T)

print(model4h , digits=6 )
summary(model4h)
DICm4h<-model4h$DIC

attach.bugs(model4h)

MapABS@data$evhmodel4 <- apply(mu,2,mean)
spplot(MapABS,"evhmodel4",main="Model 4 EVH")
#spplot(MapABS,"evhmodel4",main="Model 4 EVH",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"evhmodel4",main="Model 4 EVH",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

par(mfrow=c(1,1))

plot(density(a0, adjust = 1.5), main = expression(paste(pi,"(",a0,"|y)")), xlab= "" )
plot(density(c, adjust = 1.5), main = expression(paste(pi,"(",c,"|y)")), xlab= "" )
plot(density(sigma, adjust = 1.5), main = expression(paste(pi,"(",sigma,"|y)")), xlab= "" )
plot(density(sigma.b, adjust = 1.5), main = expression(paste(pi,"(",sigma.b,"|y)")), xlab= "" )
detach.bugs()

### GUARDEM L'OBJECTE DEL MAPA
#save(MapABS,file = "mapa.RData")
load("mapa.RData")

#### dics dones
DICm1d;DICm2d;DICm3d;DICm4d;

#### dics HOMES
DICm1h;DICm2h;DICm3h;DICm4h;

### validació models
## CALCUL RESIDUS
res1d<-MapABS@data[["e0d"]]-MapABS@data[["evdmodel1"]]
res1h<-MapABS@data[["e0h"]]-MapABS@data[["evhmodel1"]]

```



```

res2d<-MapABS@data[["e0d"]]-MapABS@data[["evdmodel2"]]
res2h<-MapABS@data[["e0h"]]-MapABS@data[["evhmodel2"]]
res3d<-MapABS@data[["e0d"]]-MapABS@data[["evdmodel3"]]
res3h<-MapABS@data[["e0h"]]-MapABS@data[["evhmodel3"]]
res4d<-MapABS@data[["e0d"]]-MapABS@data[["evdmodel4"]]
res4h<-MapABS@data[["e0h"]]-MapABS@data[["evhmodel4"]]
## VALIDACIÓ NORMALITAT
par(mfrow=c(2,2))
qqnorm(res1d,main = "Normalitat residus dones M1")
qqnorm(res1h,main = "Normalitat residus homes M1")
qqnorm(res2d,main = "Normalitat residus dones M2")
qqnorm(res2h,main = "Normalitat residus homes M2")
qqnorm(res3d,main = "Normalitat residus dones M3")
qqnorm(res3h,main = "Normalitat residus homes M3")
qqnorm(res4d,main = "Normalitat residus dones M4")
qqnorm(res4h,main = "Normalitat residus homes M4")

par(mfrow=c(2,2))
## VALIDACIÓ LINEALITAT I HOMOCEDASTICITAT

plot(MapABS@data[["evdmodel1"]],res1d,main="Prediccions E.Vida M1 Dones vs residus")
plot(MapABS@data[["evhmodel1"]],res1h,main="Prediccions E.Vida M1 Homes vs residus")
plot(MapABS@data[["evdmodel2"]],res2d,main="Prediccions E.Vida M2 Dones vs residus")
plot(MapABS@data[["evhmodel2"]],res2h,main="Prediccions E.Vida M2 Homes vs residus")
plot(MapABS@data[["evdmodel3"]],res3d,main="Prediccions E.Vida M3 Dones vs residus")
plot(MapABS@data[["evhmodel3"]],res3h,main="Prediccions E.Vida M3 Homes vs residus")
plot(MapABS@data[["evdmodel4"]],res4d,main="Prediccions E.Vida M4 Dones vs residus")
plot(MapABS@data[["evhmodel4"]],res4h,main="Prediccions E.Vida M4 Homes vs residus")

MapABS@data$res1d <- res1d
MapABS@data$res1h <- res1h
MapABS@data$res2d <- res2d
MapABS@data$res2h <- res2h
MapABS@data$res3d <- res3d
MapABS@data$res3h <- res3h
MapABS@data$res4d <- res4d
MapABS@data$res4h <- res4h
spplot(MapABS,"res1d",main="Residus model 1 Dones")
#spplot(MapABS,"res1d",main="Residus model 1 Dones",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res1d",main="Residus model 1 Dones",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res1h",main="Residus model 1 Homes")
#spplot(MapABS,"res1h",main="Residus model 1 Homes",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res1h",main="Residus model 1 Homes",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res2d",main="Residus model 2 Dones")
#spplot(MapABS,"res2d",main="Residus model 2 Dones",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))

```

```

spplot(MapABS,"res2d",main="Residus model 2 Dones",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res2h",main="Residus model 2 Homes")
#spplot(MapABS,"res2h",main="Residus model 2 Homes",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res2h",main="Residus model 2 Homes",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res3d",main="Residus model 3 Dones")
#spplot(MapABS,"res3d",main="Residus model 3 Dones",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res3d",main="Residus model 3 Dones",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res3h",main="Residus model 3 Homes")
#spplot(MapABS,"res3h",main="Residus model 3 Homes",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res3h",main="Residus model 3 Homes",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res4d",main="Residus model 4 Dones")
#spplot(MapABS,"res4d",main="Residus model 4 Dones",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res4d",main="Residus model 4 Dones",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))
spplot(MapABS,"res4h",main="Residus model 4 Homes")
#spplot(MapABS,"res4h",main="Residus model 4 Homes",xlim = c( 390000, 441766),ylim =
c(4559500.7,4611532))
spplot(MapABS,"res4h",main="Residus model 4 Homes",xlim = c( 390000,486555.1),ylim =
c(4559500.7,4631532))

veins<-nb2listw(neighbours = veinatges,style="B",zero.policy =T)
#moran.test(MapABS@data$evdmodel4,listw = veins,zero.policy = T)
#moran.test(MapABS@data$res4d,listw = veins,zero.policy = T) NA als residus
#moran.test(MapABS@data$evhmodel4,listw = veins,zero.policy = T)

MapABS@data$res1d_sna<-MapABS@data$res1d
MapABS@data$res1d_sna[is.na(MapABS@data$res1d_sna)]<-0
moran.test(MapABS@data$res1d_sna,listw = veins,zero.policy = T)
cor1d<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res1d_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor1d)
plot(x=1:8,y=cor1d$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M1D",ylim=c(-0.1,0.2))
abline(h=0)

MapABS@data$res1h_sna<-MapABS@data$res1h
MapABS@data$res1h_sna[is.na(MapABS@data$res1h_sna)]<-0
moran.test(MapABS@data$res1h_sna,listw = veins,zero.policy = T)
cor1h<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res1h_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor1h)

```

```

plot(x=1:8,y=cor1h$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M1H",ylim=c(-0.1,0.2))
abline(h=0)
#####
MapABS@data$res2d_sna<-MapABS@data$res2d
MapABS@data$res2d_sna[is.na(MapABS@data$res2d_sna)]<-0
moran.test(MapABS@data$res2d_sna,listw = veins,zero.policy = T)
cor2d<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res2d_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor2d)
plot(x=1:8,y=cor2d$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M2D",ylim=c(-0.1,0.2))
abline(h=0)

MapABS@data$res2h_sna<-MapABS@data$res2h
MapABS@data$res2h_sna[is.na(MapABS@data$res2h_sna)]<-0
moran.test(MapABS@data$res2h_sna,listw = veins,zero.policy = T)
cor2h<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res2h_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor2h)
plot(x=1:8,y=cor2h$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M2H",ylim=c(-0.1,0.2))
abline(h=0)
###

MapABS@data$res3d_sna<-MapABS@data$res3d
MapABS@data$res3d_sna[is.na(MapABS@data$res3d_sna)]<-0
moran.test(MapABS@data$res3d_sna,listw = veins,zero.policy = T)
cor3d<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res3d_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor3d)
plot(x=1:8,y=cor3d$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M3D",ylim=c(-0.1,0.2))
abline(h=0)

MapABS@data$res3h_sna<-MapABS@data$res3h
MapABS@data$res3h_sna[is.na(MapABS@data$res3h_sna)]<-0
moran.test(MapABS@data$res3h_sna,listw = veins,zero.policy = T)
cor3h<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res3h_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor3h)
plot(x=1:8,y=cor3h$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M3H",ylim=c(-0.1,0.2))
abline(h=0)
####

MapABS@data$res4d_sna<-MapABS@data$res4d
MapABS@data$res4d_sna[is.na(MapABS@data$res4d_sna)]<-0
moran.test(MapABS@data$res4d_sna,listw = veins,zero.policy = T)

```

```
cor4d<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res4d_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor4d)
plot(x=1:8,y=cor4d$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M4D",ylim=c(-0.1,0.2))
abline(h=0)
```

```
MapABS@data$res4h_sna<-MapABS@data$res4h
MapABS@data$res4h_sna[is.na(MapABS@data$res4h_sna)]<-0
moran.test(MapABS@data$res4h_sna,listw = veins,zero.policy = T)
cor4h<-sp.correlogram(neighbours = veins[["neighbours"]],var = MapABS@data$res4h_sna,order =
8,method = "I",style = "C",zero.policy = T)
plot(cor4h)
plot(x=1:8,y=cor4h$res[,1],type="h",xlab="lags",ylab="Moran's I",main="Correlograma
M4H",ylim=c(-0.1,0.2))
abline(h=0)
```