



INSTITUTO GALEGO DE ESTADÍSTICA

Utilización do software R nunha oficina de
estadística pública

Instituto Galego de Estatística

María Martín Vila

Que facemos?

O Instituto Galego de Estatística (IGE) é un organismo autónomo da Xunta de Galicia creado no ano 1988 e que se rexe basicamente pola Lei 9/1988 de Estatística de Galicia



- recompilación e difusión da documentación estatística dispoñible
- desenvolver bases de datos de interese público
- analizar as necesidades e a evolución da demanda de estatísticas e asegurar a súa difusión

Como o facemos?



Outros: dgt,
seg-social,...





Lectura de datos



Manipulación



Difusión



Datos básicos de Galicia		Período	Data
Superficie (km ²)			29.574,4
Población (INE)	2013(P)		2.763.499
Tasa bruta de natalidade (vivos) (ISE)	2011		7,7
Esperanza de vida ao nacer (EVD)	2011		82,4
Tasa de actividade (%) (OGE-INE)	2013(R)		54,7
Tasa de paro (%) (OGE-INE)	2013(R)		22,4

Últimos datos de Galicia		Período	Data
Variación hou ano %			
Produto Interior Bruto (PIB(m)) (OGE)	2013		-1,4
Índice de produción industrial (INE)	2013		-0,3
Traballadores afiliados á S.S. (MTAS)	2013		2,7
Parados rexistrados (SPE)	2013		0,5
Ocupados (OGE-INE)	2013		-3,4
Evolución (IASAD)	2013		1,8

Lectura de datos doutros organismos (ancho fixo):

```
read.fwf(file, widths, header = FALSE, sep = "\t", skip = 0, row.names,  
col.names, n = -1,bufferize = 2000, ...)
```

- Microdatos do INE: Encuesta de Estructura Salarial

```
datos<-read.fwf("EES10_WEB",widths=c(8,2,1,2,1,1,1,1,1,1,2,1,1,2,2,1  
,1,2,2,2,2,4,2,2,3,2,1,2,1,2,9,9,9,9,9,9,6,7,2,2,1,3,1,3,1,3,1,3,10,9,9,2,12))
```

- Ficheiros txt da dgt: matriculacións mensuais

```
matriculacions<-read.fwf("MATM092013.txt",widths=c(8,1,1,1,2,5,2,8,1 ,1,8))
```

Lectura de datos de outros organismos (bases de datos):

- Instalar paquete RODBC: `install.packages("RODBC")`
- Crear unha conexión odbc
- Conectar: `bd <- odbcConnect("basededatos")`
- Podemos extraer unha táboa completa: `sqlFetch`
- Ou unha consulta en sql

➤ Datos de contratos en acces:

```
ContratosSector<- sqlFetch(Contratos,"CONTRATOS_TIPOLOXIA_SECTOR")
```

➤ Datos de paro rexistrado en sql:

```
Paro_mes<-sqlQuery(fontes, "select ANO, MES, MUN_RES_PFIS, SEXO,  
ACT_ECONOMICA, PARADOS from prx200501_ where ANO=2013 and MES=9")
```

Lectura de ficheiros web IGE:

Podemos ler datos directamente da web do IGE coa función: read.csv()

➤ Poboación :

Obter URL de descarga

Lectura de ficheiros Eurostat (.tsv comprimidos):

Proporción de asalariados con salarios baixos: earn_ses_pub1s.tsv.gz

Lectura directa:

```
R Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda
[Icons]
> library(RCurl)
> temp <- paste(tempfile(), ".gz", sep="")
> download.file("http://epp.eurostat.ec.europa.eu/NavTree_prod/everybody/BulkDownloadListing?sort=1&file=data/earn_ses_pub1s.tsv.gz",
  probando la URL 'http://epp.eurostat.ec.europa.eu/NavTree_prod/everybody/BulkDownloadListing?sort=1&file=data/earn_ses_pub1s.tsv.gz'
  Content type 'application/x-gzip' length 1038 bytes
  URL abierta
  downloaded 1038 bytes
> dataconnection <- gzfile(temp)
> tabla<-read.table(dataconnection)
> head(tabla)
      V1      V2      V3
1 unit,sex,sizeclas,geo\\time 2010 2006
2      PC,F,GE10,AT 24.76 25.32
3      PC,F,GE10,BE 10.33 11.06
4      PC,F,GE10,BG 21.55 19.51
5      PC,F,GE10,CH 16.92      :
6      PC,F,GE10,CY 31.44 34.18
>
```

Descarga e descompresión do ficheiro

Lemos os datos con read.table que toma como separador por defecto o espazo en branco

Lectura de ficheiros Eurostat (.tsv):

Lectura mediante a función LeeEurostat:

```
> leeEurostat<-function(file,nct){  
+  
+ baseurl="http://epp.eurostat.ec.europa.eu/NavTree_prod/everybody/BulkDownloadListing?sort=1&file=data/"  
+ fullfilename=paste(file, ".tsv.gz", sep="")  
+ temp <- paste(tempfile(), ".gz", sep="")  
+ download.file(paste(baseurl, fullfilename, sep=""), temp)  
+ dataconnection <- gzfile(temp)  
+  
+ pre<-" "  
+ for(i in 1:nct) {pre<-paste(sep=" ", pre, ".*?\t")}  
+ x<-readLines(dataconnection)  
+ x<-gsub(" ", "\t", x, fixed=T)  
+ limpia<-function(a){  
+ inicio<-gsub(paste(sep=" ", "(", pre, ")", ".*" ), "\\1", a)  
+ final<-gsub("[abcdefghijklmnopqrstuvwxyz]", "", gsub(paste(sep=" ", pre, "(.*)"), "\\1", a) )  
+ return(paste(sep=" ", inicio, final))  
+ }  
+ x[2:length(x)]<-limpia(x[2:length(x)])  
+  
+ f<-tempfile()  
+ write.table(x, f, quote=F, sep="\t", row.names=F, col.names=F)  
+ x<-read.delim(f, na.strings = ": ")  
+ for( i in (nct+1):length(x)) print(class(x[[i]])=="numeric" )  
+  
+ return(x)  
+ }
```

Descarga e descompresión do ficheiro

Separación de variables e eliminación de caracteres intermedios

Saída de datos en formato dataframe coas variables correspondentes e os anos en columnas

Lectura de ficheiros Eurostat (.tsv comprimidos):

```
R Console
> library(RCurl)
> source("R:/Servicios/Difusion/OPERACIÓN S ESTATÍSTICAS/ACTIVIDADES-PUBLICACIONES/ESTUDO SALARIOS/ESTRUCTURA S
> file="earn_ses_publis"
> nct=4
> datos<-leeEurostat(file,nct)
probando la URL 'http://epp.eurostat.ec.europa.eu/NavTree_prod/everybody/BulkDownloadListing?sort=1&file=data/
Content type 'application/x-gzip' length 1038 bytes
URL abierta
downloaded 1038 bytes

[1] TRUE
[1] TRUE
> head(datos)
  unit sex sizeclas geo.time X2010 X2006
1  PC  F      GE10      AT  24.76 25.32
2  PC  F      GE10      BE  10.33 11.06
3  PC  F      GE10      BG  21.55 19.51
4  PC  F      GE10      CH  16.92  NA
5  PC  F      GE10      CY  31.44 34.18
6  PC  F      GE10      CZ  24.53 25.08
> |
```

Saída de datos en formato dataframe coas variables correspondentes e os anos en columnas

O ano non é unha variable → No proceso de manipulación transformaremos este dataframe nun coa estrutura :

```
head(datos.hip)
  Tempo Sexo Pais Dato
  2010 Total Unión Europea (27 países) 16,96
  2010 Total Bélgica 6,37
```

Manipulación de datos:

Empresas por 1.000 habitantes segundo o grao de urbanización

Poboación por concello
(Web IGE)

```
> head(poboacion)
  Tempo CodEspazo DatoN
1  1998     15006  6947
2  1998     15010  2691
3  1998     15066  5004
```

Número de empresas por concello
(Web IGE)

```
> head(empresas)
  Tempo CodEspazo DatoN
1  1999     15006   406
2  1999     15010   107
3  1999     15066   198
```

Clasificación dos concellos
segundo o grao de urbanización
(csv a partir de excel)

```
head(clas)
CodEspazo Espazo Grao
15001 Abegondo ZPP
15002 Ames ZIP
15003 Aranga ZPP
```

Único ficheiro R: datos



MERGE

```
pobemp<-merge(empresas,poboacion,by=c("CodEspazo","Tempo"),all.x=TRUE)
```

```
datos<-merge(pobemp,clas,by.x="CodEspazo",by.y="Código")
```

Manipulación de datos:

Datos:

```
> head(datos)
  Tempo CodEspazo  Espazo Grao Poboacion Empresas
1  1999      15001 Abegondo  ZPP         263      5480
2  2000      15001 Abegondo  ZPP         269      5594
3  2001      15001 Abegondo  ZPP         286      5694
4  2002      15001 Abegondo  ZPP         287      5772
5  2003      15001 Abegondo  ZPP         297      5761
6  2004      15001 Abegondo  ZPP         319      5732
> |
```

Agregamos os datos de poboación e empresas:

AGGREGATE

```
datosg<-aggregate(datos[,c(5,6)],by=list(datos$Tempo,datos$Grao),FUN="sum")
```

Creamos unha táboa base con todos os cruces das variables e a completamos cos datos:

EXPAND.GRID

```
tablabase<-expand.grid(datosg$Tempo, datosg$Grao)
```

```
tabla<-merge(tablabase,datosg, by=c("Tempo","Grao"), all.x=TRUE)
```

Difusión de datos:

O noso dataframe final ten a seguinte estrutura:

```
> head(tabla)
  Tempo Grao Poboacion Empresas Indicador
1  1999 Total   160988   2730336  16959.87
2  1999  ZDP    61055    913016  14953.99
3  1999  ZIP    49437    810216  16388.86
4  1999  ZPP    50496   1007104  19944.23
5  2000 Total   166055   2731900  16451.78
6  2000  ZDP    62694    914364  14584.55
> |
```

Para grabalo na nosa base de datos de Mysql e visualizalo na web utilizamos unha función :

```
grabarH(5164,tabla,12)
```


Esta función permítenos grabar unha táboa nova ou añadir datos a unha táboa xa creada.

Só temos que indicarlle o número da táboa multidimensional, o dataframe cos datos e un código identificativo do espazo.

Aplicación: Táboas de mortalidade

Necesitamos calcular táboas de mortalidade simultáneas para:

- diferentes periodos de tempo
- máis dun espacio xeográfico
- todas as variantes do sexo (homes, mulleres e total)



Por que unha función nova?

Software	Periodos	Espazos xeográficos	Sexo	a_x	TMI
EPIDAT	X	X	✓	X	✓
R Demography	✓	X	X	X	X
R Lifetables	X	X	X	✓	X

R T_Mortalidad	✓	✓	✓	✓	✓
-----------------------	---	---	---	---	---

Función R: T_mortalidad.R

```
T_mortalidad <- function (data , IM_i ,TMI_i , a_ini , int_f))
```

Argumentos obrigatorios:

- Defuncións e poboación por idade e sexo
- Espazo (tipo)
- Índice de masculinidade

Argumentos optativos:

- Taxa de mortalidade infantil
- Valores a_x
- Intervalo aberto final

```
T_mortalidad <- function (data , IM_i)
```

```
T_mortalidad <- function (data, IM_i, TMI_i, a_ini, int_f)
```

T_mortalidad: Resultado



Saida formato lista → Cada elemento da lista é unha táboa de mortalidade

```
> TM<-T_mortalidad(dataq,datosIM)
> names(TM) [31]
[1] "LT Area= GA Time= 11 Sex= 0"
> TM[[31]]
  x  n      a      D      P      m      q      p      l      d      L      T      e
[1,] 0  1 0.05000931 165 63061 2.616514e-03 0.0026100265 0.9973900 100000.00 261.00265 99752.05 8213181.8 82.131818
[2,] 1  4 1.60613024  49 269104 1.820857e-04 0.0007280256 0.9992720 99739.00 72.61254 398782.16 8113429.7 81.346614
[3,] 5  5 2.50000000  30 320617 9.356959e-05 0.0004677385 0.9995323 99666.38 46.61781 498215.38 7714647.6 77.404710
[4,] 10 5 2.50000000  34 310809 1.093919e-04 0.0005468102 0.9994532 99619.77 54.47310 497962.65 7216432.2 72.439762
[5,] 15 5 2.50000000 109 359315 3.033550e-04 0.0015156255 0.9984844 99565.29 150.90370 497449.21 6718469.5 67.478026
[6,] 20 5 2.50000000 180 431242 4.173990e-04 0.0020848197 0.9979152 99414.39 207.26108 496553.80 6221020.3 62.576658
[7,] 25 5 2.50000000 231 562106 4.109545e-04 0.0020526637 0.9979473 99207.13 203.63887 495526.55 5724466.5 57.702169
[8,] 30 5 2.50000000 355 684710 5.184677e-04 0.0025889826 0.9974110 99003.49 256.31831 494376.66 5228940.0 52.815714
[9,] 35 5 2.50000000 555 665859 8.335098e-04 0.0041588828 0.9958411 98747.17 410.67792 492709.16 4734563.3 47.946318
[10,] 40 5 2.50000000 958 641400 1.493608e-03 0.0074402566 0.9925597 98336.49 731.64875 489853.35 4241854.2 43.136113
[11,] 45 5 2.50000000 1468 608625 2.411994e-03 0.0119876857 0.9880123 97604.85 1170.05621 485099.09 3752000.8 38.440723
[12,] 50 5 2.50000000 2162 573895 3.767240e-03 0.0186604523 0.9813395 96434.79 1799.51678 477675.15 3266901.7 33.876797
[13,] 55 5 2.50000000 2723 519884 5.237707e-03 0.0258500469 0.9741500 94635.27 2446.32623 467060.55 2789226.6 29.473435
[14,] 60 5 2.50000000 3815 517531 7.371539e-03 0.0361907418 0.9638093 92188.95 3336.38634 452603.76 2322166.0 25.189202
[15,] 65 5 2.50000000 4872 451942 1.078014e-02 0.0524861997 0.9475138 88852.56 4663.53320 432603.97 1869562.3 21.041175
[16,] 70 5 2.50000000 6890 414658 1.661610e-02 0.0797669739 0.9202330 84189.03 6715.50388 404156.37 1436958.3 17.068237
[17,] 75 5 2.50000000 12120 423353 2.862859e-02 0.1335822754 0.8664177 77473.52 10349.08944 361494.89 1032801.9 13.331031
[18,] 80 5 2.50000000 15967 299871 5.324623e-02 0.2349549793 0.7650450 67124.43 15771.21981 296194.12 671307.0 10.000934
[19,] 85 NA      NA 37125 271182 1.369007e-01 1.0000000000 0.0000000 51353.21 51353.21337 375112.92 375112.9 7.304566
> |
```

Outras aplicacións: Estudo de salarios

Microdatos da Encuesta de estrutura salarial

```
d1<-density(datos.sexo[[1]]$salannual,  
weights=datos.sexo[[1]]$frecuencia/sum(datos.sexo[[1]]$frecuencia))
```



Outras aplicacións: Mapas

Panorama rural- urbano

```
muni_shp=readShapeSpatial("R:/PANORAMA RURAL_URBANO/Información  
cartográfica/Municipios/CONCELLO_1000.shp")
```

```
clas=read.csv2("Clasificacion_urbanizacion.csv")
```


```
niveles=clas_ord$SubGraoUrbanización
```

```
fgs=colores [niveles]
```

```
plot(muni_shp,col=fgs)
```



Mapa dos concellos segundo o subgrao de urbanización



Outras aplicacións: Gráficos de burbullas (gapminder)

Galicia- Norte de Portugal

Ficheiro cos datos de Galicia e Portugal no período 2000-2010

```
> datos=read.csv2("datos_gapminder.csv")
> names(datos)
[1] "Espazo"          "Ano"             "Tasa.de.natalidad"
[4] "Tasa.de.mortalidad" "Tasa.de.actividad" "Tasa.de.paro"
[7] "PIB.ph"          "PIB.ph.PPC"      "Loc"
>
```

Sintaxe (emprégase a librería googleVis)

```
> library("googleVis")
> graf1=gvisMotionChart(datos,idvar="Espazo",timevar="Ano",
options=list(gvis.language="es",width=900,height=600))
> plot(graf1)
```



GRÁFICO



Gracias pola súa atención

www.ige.eu

ige@ige.eu