

El papel de la Estadística en las Ciencias Biomédicas

Santander, 14 de mayo de 2008


Carmen Cadarso-Suárez




Unidad de Bioestadística
Facultad de Medicina
Departamento de Estadística e IO

La investigación biomédica

Equipos multidisciplinarios



Bioestadística actual



Zelen M. (2006). Biostatisticians, Biostatistical Science and the Future. *Stat Med*, **25**, 3409-3414.

Lugares de trabajo

Facultad de Medicina (USC)



Facultad de Matemáticas (USC)



C. Hospitalario Clínico Universitario



Consellería de Sanidade (Xunta de Galicia)



Medicina:

“Arte de prevenir y curar enfermedades”

Medicina Básica

Biología

Neurociencia

Medicina Molecular

Biotecnología

...

Clínica

Oftalmología

Cardiología

Cirugía

Pediatría

...

Epidemiología

Estudios ecológicos

Disease mapping

Dosis-Respuesta

....

Tipos de estudios biomédicos

Asociación

- **Epidemiología y Clínica**
 - Factor de riesgo /enfermedad: Medidas: “OR”, “RR”
 - Factor de riesgo/mortalidad: “Hazard Ratio (HR)”
- **Neurociencia**
 - Asociación entre la actividad neuronal y estímulos

Clasificación

- **Diagnosis clínica**
 - Búsqueda de marcadores de enfermedades
- **Diagnóstico asistido por ordenador**
 - Evaluación y mejora de sistemas CAD

Predicción

- **Prognosis clínica**
 - Pronóstico de enfermedades y supervivencia.
- **Medicina Forense**
 - Predicción de la fecha de muerte en homicidios



EPIDEMIOLOGÍA

“Factores de riesgo y enfermedad”

Investigadores colaboradores: médicos y epidemiólogos

Departamento de Salud Pública (USC)

Complejo Clínico-Universitario de Santiago de Compostela

Dirección Xeral de Saúde Pública (Xunta de Galicia)

Medida de efecto: Riesgo Relativo (RR)

E = enfermedad

F = factor de exposición

Estudio de cohortes (incidencia)

$$RR_{F/\bar{F}} = \frac{p(E / F)}{p(E / \bar{F})}$$

$RR = 1$, no asociación entre E y F

$RR > 1$, F factor de riesgo

$RR < 1$, F factor protector

Medida de efecto: Odds-Ratio (OR)

Estudio caso-control

$$Odds(E) = \frac{p(F/E)}{p(\bar{F}/E)} \qquad Odds(\bar{E}) = \frac{p(F/\bar{E})}{p(\bar{F}/\bar{E})}$$

$$OR_{F/\bar{F}} = \frac{Odds(E)}{Odds(\bar{E})}$$

$OR = 1$, no asociación entre E y F

$OR > 1$, F factor de riesgo


$OR < 1$, F factor protector

Factores de riesgo de Infección post-quirúrgica

La glucosa, ¿es un factor de riesgo para la infección post-quirúrgica?

Modelo Aditivo Generalizado logístico (logistic GAM, Hastie-Tibshirani, 1990)



$$\log \left(\frac{p(INFEC=1/Gluc)}{p(INFEC=0/Gluc)} \right) = \text{logit} = \beta_0 + f(Gluc)$$



Modelos multivariantes


Efectos principales

$$\text{logit} = \beta_0 + \beta_1 \text{Sex} + \beta_2 \text{Age} + f_3(\text{Gluc}) + f_4(\text{Linf}\%)$$



Interacción

$$\text{logit} = \beta_0 + \beta_1 \text{Sex} + \beta_2 \text{Age} + f_3(\text{Gluc}) + f_4(\text{Linf}\%) + f_{34}(\text{Gluc}, \text{Linf}\%)$$





NEUROCIENCIA

“Actividad neuronal y conducta”

Investigadores colaboradores: fisiólogos, psicólogos

Departamento de Fisiología(USC)

Laboratorio de Neurociencia Computacional (USC)

Actividad neuronal y conducta


En la Corteza Visual (en primates subhumanos) interesa estudiar:

- Asociación entre estímulos visuales y la respuesta neuronal:
Tasa de descarga eléctrica
- Disparo simultáneo de varias neuronas:
Sincronía neuronal
- Poblaciones de neuronas:
Population-based neuron analysis.

Estos abordajes experimentales nos permiten conocer:

1. Cómo se procesa la **información sensorial** en el cerebro.
- 2.Cuál es la relación entre la **actividad neuronal** y la **conducta**.

“Doctrina” de la neurona




Ramón y Cajal (Premio Nobel, 1906)


La neurona es una entidad discreta que conduce corriente eléctrica.




El SNC está formado por neuronas que conectan entre sí por medio de *sinapsis* produciendo redes neuronales



Visual Cortex (Área V1)



David H. Hubel (1988) Eye, Brain and Vision. Scientific American Library. New York.



Tarea de decisión en la orientación

¿derecha? ¿izquierda?





Fig. 1. Outline of the orientation discrimination task described in the text: RT, reaction time; MT, movement time

Codificación de la actividad neuronal




spikes


inter-spike intervals

Tasa de disparo neuronal (1 neurona)

Raster Plot





Peri-stimulus Histogram (PSTH)



Comparación de tasas de disparo



$$\log \left\{ \frac{p(\text{Orien}, t)}{1 - p(\text{Orien}, t)} \right\} = \alpha + f(t) + f_0(t)I_{\{\text{Orien}=0\}} + f_1(t)I_{\{\text{Orien}=1\}}$$

$$\text{OR}(t) = \frac{p(1, t) / \{1 - p(1, t)\}}{p(0, t) / \{1 - p(0, t)\}}$$





Comparación de tasas de disparo

Easy task



Difficult task



Sincronía neuronal

Tasa de disparo conjunta (2 neuronas) : Joint PSTH






Figure 2: Raster plot (left) of spikes and corresponding peristimulus

Sincronía neuronal

Neuron #1




Neuron #2



Spike coincidence

		Neuron k		Totals
		1	0	
Neuron i	1	n_{11}	n_{10}	$n_{11} + n_{10}$
	0	n_{01}	n_{00}	$n_{01} + n_{00}$
Totals		$n_{11} + n_{01}$	$n_{10} + n_{00}$	$N = n_{11} + n_{10} + n_{01} + n_{00}$



Medida de Sincronía

Tasa marginal de la neurona 1: $\pi_{1+}(t) = p(Y_1 = 1/t)$

Tasa marginal de la neurona 2: $\pi_{+1}(t) = p(Y_2 = 1/t)$

Tasa conjunta de disparo: $\pi_{11}(t) = p(Y_1 = 1, Y_2 = 1/t)$

Sincronía Condicional

$$CSM(t) = \frac{\pi_{11}(t)}{\pi_{1+}(t) + \pi_{+1}(t) - \pi_{11}(t)}$$


Modelo Plackett-Dale

Supongamos que interesa estudiar la sincronía bajo ciertas condiciones experimentales del experimento, $\mathbf{x}$.

$$\left\{ \begin{array}{l} \log \frac{\pi_{+1}(t, \mathbf{x})}{1 - \pi_{+1}(t, \mathbf{x})} = \alpha_{01} + \beta_1^T \mathbf{x}(t) \\ \log \frac{\pi_{1+}(t, \mathbf{x})}{1 - \pi_{1+}(t, \mathbf{x})} = \alpha_{02} + \beta_2^T \mathbf{x}(t) \\ \log \frac{CSM(t, \mathbf{x})}{1 - CSM(t, \mathbf{x})} = \alpha_{03} + \beta_{11}^T \mathbf{x}(t) \end{array} \right.$$

Sincronía temporal

Orientación (en grados) de la barra = 85, 90, 95





RADIOLOGÍA


**“Evaluación de sistemas diagnósticos asistidos por ordenador
CAD (Computer-Aided Diagnostic Systems)”**

Investigadores colaboradores: físicos, médicos, informáticos

Departamento de Electrónica y Ciencias de la Computación (USC)
Laboratorio de Imagen Radiológica (USC)


Evaluación diagnóstica de sistemas CAD

**Radiografía
(mama)**



Lesión:
Cúmulo (real) de
microcalcificaciones

**CAD
Computer-Aided
Diagnosis**




FP (False Positive)

TP (True Positive)

Curva ROC (*Receiver Operating Characteristic*)

- Medida de precisión diagnóstica de tests (marcadores) con respuesta continua, Y
- Proponiendo un punto de corte “ c ” para clasificar a enfermos y sanos ($D, \bar{D}$)



$$TPF(c) = P[Y \geq c / D] = \text{Sensitivity}$$

$$FNF(c) = P[Y < c / D]$$

$$TNF(c) = P[Y < c / \bar{D}] = \text{Specificity}$$

$$FPF(c) = P[Y \geq c / \bar{D}]$$

Definiciones


Curva ROC

$$R(\cdot) = \{(FPF(c), TPF(c)), c \in (-\infty, \infty)\}$$

$$R(\cdot) = \{(t, ROC(t)), t \in (0, 1)\} \quad FPF(c) = t \quad ROC(t) = TPF(c)$$

Área bajo la Curva (*Area Under the Curve, AUC*)

$$AUC = \int_0^1 ROC(t) dt$$



ROC condicional



Test diagnóstico: Tamaño del cúmulo.

Status: 1=cúmulo real, 0=no.

Condicionado por:

Nivel de gris de la mamografía digital.

Tipo de tejido de la mama (denso/graso).



Medicina Forense



"Was the coroner able to establish the cause of death, constable?"

Colaboración: Instituto de Medicina Legal (USC)

Predicción del intervalo post-mortem

- La estimación del **intervalo post-mortem (PMI)** es un problema fundamental en la Medicina Forense.
- Debido a que la mayoría de las víctimas de homicidio son descubiertas en las primeras horas resulta trascendente disponer de algún método que permita realizar una estima en ese intervalo.
- Métodos tradicionales (temperatura corporal, rigor/livor mortis,...) están siendo sustituidos por determinaciones bioquímicas presentes en diversos fluidos corporales, como el humor vítreo.
- **Sustancias bioquímicas** de interés: Urea [U], Hipoxantina [Hx], Potasio [K+].
- Información adicional: **tipo de homicidio** (ahorcamiento, otros).

$$\log(PMI) = \beta_0 + \beta_1[K^+] + \beta_2[Hx] + \beta_3[U] + \varepsilon$$

Modelos estadísticos de predicción

Modelo lineal (LR)

$$\log(PMI) = \beta_0 + \beta_1[K^+] + \beta_2[Hx] + \beta_3[U] + \varepsilon$$

Modelo Aditivo (AM, Hastie-Tibshirani, 1990)

$$\log(PMI) = \alpha_0 + f_1([K^+]) + f_2([Hx]) + f_3([U]) + \varepsilon$$

Modelo Aditivo con interacciones (AM2)


$$\begin{aligned} \log(PMI) = & \alpha_0 + f_3([U]) + f_{11}([K^+]1_{D=1}) + f_{21}([Hx]1_{D=1}) \\ & + f_{12}([K^+]1_{D=2}) + f_{22}([Hx]1_{D=2}) + \varepsilon \end{aligned}$$

Support Vector Machines(SVM, Statistical Learning Theory, Vapnik 1995)

$$\log(PMI) = \sum_{i=1}^n \beta_i k((([U], [K^+], [Hx], D), ([U], [K^+], [Hx], D)_i) + \varepsilon$$


Validación de los métodos

- 1) En este estudio se separó la muestra inicial en dos partes:
70% datos: “training” set.
30% datos: “validation” set.
- 2) Se generaron $B=10.000$ particiones aleatorias de la muestra inicial.
- 3) Para cada una de estas particiones se calculó el **error cuadrático medio (MSE)** sobre la muestra de validación, calculando el modelo con la muestra de entrenamiento.



pmicalc ()

Programa en lenguaje R, que permite obtener la predicción del PMI



The image shows a graphical user interface window titled "Post Mortem Interval Calculator". The window has a title bar with standard minimize, maximize, and close buttons. The main area is titled "Please enter Variables" and contains several input fields and a checkbox. The inputs are: [K+] with value 7 and range [5, 11]mmol/l; [Hx] with value 50 and range [10, 130]umol/l; [U] with value 40 and range [18, 100]mg/dl; Sig. Level with value 0.05; and Plot? with a checked checkbox. At the bottom, there are two buttons: "Calculate" and "Close".

Variable	Value	Range
[K+]	7	[5, 11]mmol/l
[Hx]	50	[10, 130]umol/l
[U]	40	[18, 100]mg/dl
Sig. Level	0.05	
Plot?	☒	

- Salidas numéricas.
- Salidas gráficas.

Please enter Variables

[K+]	7	[5, 11]mmol/l
[Hx]	50	[10, 130]umol/l
[U]	40	[18, 100]mg/dl
Sig. Level	0.05	
Plot?	☒	

Calculate


Close

[K]= 7 mmol/l [Hx]= 50 umol/l [Urea] 40 mg/dl

```



----- Time in hours -----
{Models } {Qu:2.5% } { Pred } {Qu:97.5% } {Hanging }
{AM } { 6.310 } { 7.528 } { 8.982 } { N/A } [K] [Hx] [U]
{AM } { 6.337 } { 7.245 } { 8.283 } { N/A } [K] [U]
{SVM } { 5.621 } { 6.944 } { 8.577 } { N/A } [K] [Hx] [U]
{SVM } { 5.739 } { 7.552 } { 9.938 } { N/A } [K] [U]
{AM2 } { 4.560 } { 6.148 } { 8.290 } { Yes } [K] [Hx] [U]
{AM2 } { 5.216 } { 6.288 } { 7.580 } { Yes } [K] [U]
{SVM } { 3.847 } { 5.261 } { 7.195 } { Yes } [K] [Hx] [U]
{SVM } { 4.528 } { 5.884 } { 7.645 } { Yes } [K] [U]
{AM2 } { 6.962 } { 8.287 } { 9.865 } { No } [K] [Hx] [U]
{AM2 } { 6.428 } { 7.362 } { 8.433 } { No } [K] [U]
{SVM } { 5.566 } { 7.612 } { 10.409 } { No } [K] [Hx] [U]
{SVM } { 5.269 } { 6.846 } { 8.895 } { No } [K] [U]

```





Modelo AM2

hanging




not hanging




Predicción: Modelos SVM y AM2

SVM: [Urea]=40 & [Hanging]=FALSE




AM2: [Urea]=40 & [Hanging]=FALSE



¿Cómo accede el forense?

El programa se encontrará en breve en la página web oficial de la
Academia Internacional de Medicina Legal





ELABORACIÓN DE SOFTWARE

**“ Una necesidad para la diseminación
de nuevas metodologías estadísticas y su aplicación práctica”**



El entorno R

- Lenguaje de programación “orientado a objetos”.
- Permite realizar cálculos matemáticos potentes.
- Potentes herramientas gráficas.
- Distribución libre (**<http://cran.r-project.org/>**).
- Gran variedad de métodos estadísticos (clásicos y novedosos).
- Librerías estadísticas (Packages).
- Las funciones son de “código abierto”.



R logo

The Comprehensive R Archive Network

Frequently used pages

CRAN

[Mirrors](#)
[What's new?](#)
[Task Views](#)
[Search](#)

About R
[R Homepage](#)

Software

[R Sources](#)
[R Binaries](#)
[Packages](#)
[Other](#)

Documentation

[Manuals](#)
[FAQs](#)
[Contributed](#)
[Newsletter](#)

Download and Install R

Precompiled binary distributions of the base system and contributed packages, **Windows and Mac** users most likely want one of these versions of R:

- [Linux](#)
- [MacOS X](#)
- [Windows \(95 and later\)](#)

Source Code for all Platforms

Windows and Mac users most likely want the precompiled binaries listed in the upper box, not the source code. The sources have to be compiled before you can use them. If you do not know what this means, you probably do not want to do it!

- **The latest release** (2007-04-24): [R-2.5.0.tar.gz](#) (read [what's new](#) in the latest version).
- Sources of [R alpha and beta releases](#) (daily snapshots, created only in time periods before a planned release).
- Daily snapshots of current patched and development versions are [available here](#). Please read about [new features and bug fixes](#) before filing corresponding feature requests or bug reports.
- Source code of older versions of R is [available here](#).
- Contributed extension [packages](#)

Questions About R

- If you have questions about R like how to download and install the software, or what the license



CRAN

[Mirrors](#)

[What's new?](#)

[Task Views](#)

[Search](#)

About R

[R Homepage](#)

Software

[R Sources](#)

[R Binaries](#)

[Packages](#)

[Other](#)

Documentation

[Manuals](#)

[FAQs](#)

[Contributed](#)

[Newsletter](#)

[funcluster](#)
[fuzzyRankTests](#)

[g.data](#)

[GIDBN](#)

[gafit](#)

[gam](#)

[gamair](#)

[GAMBoost](#)

[gamlss.dist](#)

[gamlss.mx](#)

[gamlss.nl](#)

[gamlss.tr](#)

[gamlss](#)

[GammaTest](#)

[gap](#)

[gbev](#)

[gbm](#)

[gcl](#)

[gclus](#)

[gcmrec](#)

[gdata](#)

[GDD](#)

[gee](#)

[geepack](#)

[geiger](#)

[GenABEL](#)

[genalg](#)

[GeneCycle](#)

[Geneland](#)

[GeneNet](#)

[GeneNT](#)

[genetics](#)

[GeneTS](#)

[GenKern](#)

[geometry](#)

[geoR](#)

[Functional Profiling of cDNA Microarray Expression Data](#)

[Fuzzy Rank Tests and Confidence Intervals](#)

[Delayed-Data Packages](#)

[A package performing Dynamic Bayesian Network inference.](#)

[Genetic Algorithm for Curve Fitting](#)

[Generalized Additive Models](#)

[Data for "GAMs: An Introduction with R"](#)

[Generalized additive models by likelihood based boosting](#)

[Extra distributions to be used for GAMLSS modelling.](#)

[A GAMLSS add on package for fitting mixtute distributions](#)

[Fitting non linear parametric GAMLSS models](#)

[Generating and fitting truncated \(gamlss.family\) distributions](#)

[Generalized Additive Models for Location Scale and Shape.](#)

[Gamma Test Data Analysis](#)

[Genetic analysis package](#)

[Gradient Boosted Regression Trees with Errors-in-Variables](#)

[Generalized Boosted Regression Models](#)

[Compute a fuzzy rules or tree classifier from data](#)

[Clustering Graphics](#)

[General class of models for recurrent event data](#)

[Various R programming tools for data manipulation](#)

[GD device for creating bitmap graphics as jpeg, png or gif files](#)

[Generalized Estimation Equation solver](#)

[Generalized Estimating Equation Package](#)

[Analysis of evolutionary diversification](#)

[genome-wide SNP association analysis](#)

[R Based Genetic Algorithm](#)

[Identification of Periodically Expressed Genes](#)

[Simulation and MCMC inference in landscape genetics](#)

[Modeling and Inferring Gene Networks](#)

[Relevance or Dependency network and signaling pathway discovery](#)

[Population Genetics](#)

[Microarray Time Series and Network Analysis](#)

[Functions for generating and manipulating kernel density estimate](#)

[Mesh generation and surface tessellation](#)

[Analysis of geostatistical data](#)

Ejemplo: Infección post-quirúrgica

```
>library(foreign)
```



```
>infec<-read.spss("G:\\infec.sav", to.data.frame=T)
```

```
>names(infec)
```

```
[1] "EDAD" "SEXO" "LEUCOS" "GLUC" "DIABETES" "INFEC"
```

```
>hist(infec$GLUC)
```

```
>boxplot(infec$EDAD~infec$INFEC)
```



Regresión spline con R

```
>library(splines)
```

```
>infec.bs<-glm(INFEC~bs(GLUC,knots=c(96,113)),family=binomial,data=infec)
```

```
>summary(infec.bs)
```

Coefficients:

	Estimate	SE	z	Pr(> z)
(Intercept)	0.1426	0.9833	0.145	0.88470
bs(GLUC, knots = c(96, 113))1	-0.8820	1.3187	-0.669	0.50359
bs(GLUC, knots = c(96, 113))2	-2.6993	0.9527	-2.833	0.00461 **
bs(GLUC, knots = c(96, 113))3	0.8944	1.1492	0.778	0.43643
bs(GLUC, knots = c(96, 113))4	-1.6768	1.2508	-1.341	0.18008
bs(GLUC, knots = c(96, 113))5	-1.5406	1.4748	-1.045	0.29621

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 2281.0 on 2309 degrees of freedom
Residual deviance: 2188.5 on 2304 degrees of freedom
AIC: 2200.5


Regresión spline con R

- Vamos a representar gráficamente el efecto de la glucosa.
- Usaremos la librería **gam** de Hastie-Tibshirani.

```
>library(gam)
```

```
>infec.bs<-gam(INFEC~bs(GLUC,knots=c(96,113)),family=binomial,data=infec)
```

```
>plot(infec.bs, se=T)
```




Modelo GAM con R

- **Suavización:** thin regression splines (Wood, 2006).
- **Selección automática de los gl:** Criterio GCV.

```
>library(mgcv)
```

```
>infec.gam.gcv<-gam(INFEC~s(GLUC),family=binomial,data=infec)
```

```
>plot(infec.gam.gcv,se=T, shade=T)
```



$$df_{GCV} \approx 6$$

(gl óptimos)



CONSIDERACIONES FINALES

- 
- La Estadística (la Matemática en general) es fundamental en el desarrollo de las Ciencias Biomédicas.
 - Puede ayudar en gran manera a la “investigación traslacional en salud humana”.

VII Programa Marco Investigación (UE)

- La **comunidad biomédica** es cada vez más consciente de ello:
 - Demanda de **bioestadísticos**:
Hospitales.
Instituciones Públicas.
Centros de Investigación biomédica.
Laboratorios farmacéuticos,...
 - Demanda de **cursos** de estadística.
- La **comunidad matemática** también se involucra:
 - Creación del **Instituto Español de Matemáticas (IeMath)**.
 - Proyecto Nacional **Ingenio-Mathematica**.

Bioestadística

