


Regresión Logística

La distribución de probabilidades logística


Supongamos que estamos interesados en la ocurrencia de un evento “A”, cuya probabilidad de aparición es “P”, es decir: $P(A) = P$ y por consiguiente la probabilidad de que “A” no ocurra es $P(A') = 1 - P$, sin embargo sabemos que la ocurrencia de A, y por ende su probabilidad, está relacionada con el valor que tome una variable aleatoria X, esto es $P(A) = P(X \leq x)$: por ejemplo si A: una persona muere y X es la edad de la persona, es razonable pensar que $P(\text{morir}) = P(\text{Edad} \leq \text{edad})$. Notar que $P(A) = F(X)$, donde F(X) es la función de distribución de probabilidades de X. El problema fundamental es como relacionar la probabilidad de la aparición del evento “A”, con los posibles valores de la variable X.

Luego ¿Cómo hacer para que la P(A) dependa linealmente de X?, la respuesta directa a este problema sería proponer: $P(A) = \alpha + \beta \cdot X$, sin embargo esta propuesta no es satisfactoria ya que $P(A) \in [0,1]$ y la función lineal puede tomar cualquier valor real. Si deseamos perseverar en la asociación lineal de la P(A) con X, debemos pensar en una transformación de P(A) que garantice que tome valores en todos los reales. Las propuestas que resuelven el problema son muchas, sin embargo la más útil es la siguiente:

- Si consideramos el Odds del evento A, es decir $Odds(A) = \frac{P(A)}{1-P(A)}$ y lo evaluamos para todos los posibles valores de P(A), obtenemos la siguiente función:



Observamos, como es sabido que el Odds, puede tomar cualquier valor real positivo, esto nos ilumina a considerar el logaritmo del Odds, ya que la función logaritmo tiene dominio en los reales positivos pero su recorrido son todos los reales, como se observa en el siguiente gráfico:



- Así entonces proponemos la relación:

$$\ln\left(\frac{P}{1-P}\right) = \alpha + \beta \cdot X$$

Que nos lleva a :

$$P(A) = F(X) = \frac{e^{\alpha + \beta \cdot X}}{1 + e^{\alpha + \beta \cdot X}}$$


De donde deducimos que la función densidad de probabilidades es:

$$f(X) = \frac{\beta e^{\alpha + \beta \cdot X}}{(1 + e^{\alpha + \beta \cdot X})^2}$$

Particularmente si consideramos $\alpha=0$ y $\beta=1$, la función densidad de probabilidades es:

$$f(X) = \frac{e^X}{(1 + e^X)^2}$$

Cuyo gráfico es el siguiente:



La esperanza y la varianza de la distribución logística estándar son respectivamente:

$$E[X] = 0$$


$$Var[X] = \frac{\pi^2}{3}$$

En consecuencia para la distribución logística de parámetros α y β se tiene:

$$E[X] = \alpha$$

$$Var[X] = \frac{(\beta\pi)^2}{3}$$

Usando estos resultados se encuentra un hecho sorprendente: la función de distribución de la logística estándar, difiere muy poco con la función de distribución de la $N(0, \frac{\pi^2}{3})$, como lo muestra el siguiente gráfico:



Para la distribución logística estándar se verifica:

- $1 - F(X) = \frac{1}{1+e^X}$
- $f(X) = F(X)[1 - F(X)]$

La regresión logística

Nos interesa modelar la aparición de un evento, A, explicándolo por un perfil definido como una combinación lineal de variables:

$$X\beta = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_p X_p$$

La respuesta la codificamos de la siguiente forma:

$$Y = \begin{cases} 1, & \text{si el evento A aparece} \\ 0, & \text{si el evento A no aparece} \end{cases}$$

Definiendo $P(Y = 1|X) = P(A) = \pi(X)$, es claro que la distribución de probabilidades de Y es Bernoulli con probabilidad de éxito $\pi(X)$, es decir la función de cuantía de probabilidades es:

$$P(Y = y) = (1 - \pi(X))^{1-y} \pi(X)^y, \text{ con } y = 0, 1$$

Al asumir que $\pi(X) = F(X)$ donde F(X) es la función de distribución logística evaluada en el perfil $X\beta$, la cuantía de probabilidades de Bernoulli se puede escribir como:

$$P(Y = y | X) = \left(\frac{1}{1 + e^{X\beta}} \right)^{1-y} \left(\frac{e^{X\beta}}{1 + e^{X\beta}} \right)^y, \text{ con } y = 0,1$$

Por lo tanto si se tiene una muestra aleatoria de “n” perfiles asociados a sus respectivas respuestas “y”, la función de verosimilitud que estima los parámetros β del modelo es:

$$L = \prod_{i=1}^n \left(\frac{1}{1 + e^{X_i\beta}} \right)^{1-y_i} \left(\frac{e^{X_i\beta}}{1 + e^{X_i\beta}} \right)^{y_i}, \text{ con } y_i = 0,1$$

Esta función de verosimilitud corresponde al modelo logístico de respuesta binaria. Los parámetros hay que estimarlos mediante el método iterativo de Newton-Raphson, como se revisó en el capítulo I.

Como se estableció anteriormente:

$$\ln \left(\frac{P(Y = 1 | X)}{1 - P(Y = 1 | X)} \right) = \ln(\text{Odds}(Y = 1 | X\beta)) = X\beta$$

Esta relación permite comparar dos perfiles: X y X' pues al evaluar la expresión anterior en cada uno de estos perfiles y luego restar estas ecuaciones se obtiene:

$$\begin{aligned} \ln(\text{Odds}(Y = 1 | X)) &= X\beta \\ \ln(\text{Odds}(Y = 1 | X')) &= X'\beta \end{aligned}$$



$$\ln(\text{Odds}(Y = 1 | X)) - \ln(\text{Odds}(Y = 1 | X')) = X\beta - X'\beta = (X - X')\beta$$

O equivalentemente:

$$\ln \left(\frac{\text{Odds}(Y = 1 | X)}{\text{Odds}(Y = 1 | X')} \right) = \ln(OR) = X\beta - X'\beta = (X - X')\beta$$

Por lo tanto β , es el cambio del $\ln(OR)$ por cambio de perfil, de donde se deduce que:

$$OR = e^{(X - X')\beta}$$

Si X es una variable dicotómica, por ejemplo $X=1$ y $X=0$ denoten exposición y no exposición respectivamente, la expresión del OR es:

$$OR = e^{(X - X')\beta} = e^{(1-0)\beta} = e^{\beta}$$

Cuya interpretación ya es conocida.

La novedad es que si X es una variable continua y comparamos el perfil X con el perfil $X+1$, la expresión que define el OR entre perfiles es:

$$OR = e^{(X - X')\beta} = e^{(X+1 - X)\beta} = e^{\beta}$$


Que representa el cambio de riesgo cuando la variable X se incrementa en “una unidad”.

STATA provee dos comandos equivalentes para estimar un modelo de regresión logística binaria:

- 1) logit respuesta variables, que reporta los β estimados
- 2) logistic respuesta variables, que reporta los respectivos OR

Ejemplo 1: Estimar la fuerza de la asociación en la siguiente tabla:

	Cáncer de vesícula	Control	
Consumo ají rojo	30	45	75
No consumo de ají rojo	10	55	65
	40	100	140



	Ca_ves	Aji	frec
1	1	1	30
2	1	0	10
3	0	1	45
4	0	0	55

```
. cc Ca_ves Aji [freq= frec]
```

	Exposed	Unexposed	Total	Proportion Exposed
Cases	30	10	40	0.7500
Controls	45	55	100	0.4500
Total	75	65	140	0.5357
	Point estimate		[95% Conf. Interval]	
Odds ratio	3.666667		1.528998	9.270422 (exact)
Attr. frac. ex.	.7272727		.3459769	.8921301 (exact)
Attr. frac. pop	.5454545			

	chi2(1) =		10.34	Pr>chi2 = 0.0013

```
. logistic Ca_ves Aji [freq= frec]
```

```
Logistic regression              Number of obs   =      140
                                LR chi2(1)         =      10.75
                                Prob > chi2         =      0.0010
Log likelihood = -78.381871       Pseudo R2      =      0.0642
```

Ca_ves	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
Aji	3.666667	1.528328	3.12	0.002	1.619856 8.299778

```
. logit Ca_ves Aji [freq= frec]
```

```
Iteration 0:  log likelihood = -83.757742
Iteration 1:  log likelihood = -78.492222
Iteration 2:  log likelihood = -78.382053
Iteration 3:  log likelihood = -78.381871
```

```
Logistic regression              Number of obs   =      140
                                LR chi2(1)         =      10.75
                                Prob > chi2         =      0.0010
Log likelihood = -78.381871       Pseudo R2      =      0.0642
```

Ca_ves	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
Aji	1.299283	.4168167	3.12	0.002	.4823373 2.116229
_cons	-1.704748	.3437741	-4.96	0.000	-2.378533 -1.030963

```
. dis exp( 1.299283)
3.6666667
```

Ejemplo 2: Estimar la fuerza de la asociación de la glicemia con la mortalidad intrahospitalaria por IAM (en la base de datos glicemiamorintra.dta)

```
. logistic morintra glicemia
```

```
Logistic regression               Number of obs   =       350
                                LR chi2(1)         =       14.68
                                Prob > chi2         =       0.0001
Log likelihood = -112.89033        Pseudo R2      =       0.0611
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
morintra	1.005852	.0015213	3.86	0.000	1.002875 1.008838

El efecto sexo:

```
. logistic morintra sexo
```

```
Logistic regression               Number of obs   =       350
                                LR chi2(1)         =       7.76
                                Prob > chi2         =       0.0053
Log likelihood = -116.35056        Pseudo R2      =       0.0323
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
sexo	2.7	.9455727	2.84	0.005	1.359135 5.363705

El efecto glicemia ajustando por sexo:

```
. logistic morintra glicemia sexo
```

```
Logistic regression               Number of obs   =       350
                                LR chi2(2)         =       21.44
                                Prob > chi2         =       0.0000
Log likelihood = -109.51338        Pseudo R2      =       0.0891
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
glicemia	1.005747	.0015373	3.75	0.000	1.002738 1.008764
sexo	2.593596	.9369891	2.64	0.008	1.277581 5.265215

Evaluación de la posible interacción de la glicemia con sexo:

```
. logistic morintra glicemia sexo glic_sexo
```

```
Logistic regression               Number of obs   =       350
                                LR chi2(3)         =       21.73
                                Prob > chi2         =       0.0001
Log likelihood = -109.36633        Pseudo R2      =       0.0904
```

	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]
glicemia	1.006353	.0019239	3.31	0.001	1.002589 1.01013
sexo	3.702559	2.767778	1.75	0.080	.8554656 16.02513
glic_sexo	.9982576	.0032058	-0.54	0.587	.9919941 1.004561

Ejemplo 3: Se aleatorizan 150 pacientes a tres tratamientos, cuya respuesta es dicotómica: mejora o no mejora, si el tratamiento 1 es el de referencia, comparar los tratamientos 2 y 3. (tretrat.dta)

```
. tab trat mejora, row
```

+-----+			
Key			
+-----+			
frequency			
row percentage			
+-----+			
0: no mejora 1: mejora			
trat	0	1	Total
+-----+			
1	19	31	50
	38.00	62.00	100.00
+-----+			
2	13	37	50
	26.00	74.00	100.00
+-----+			
3	10	40	50
	20.00	80.00	100.00
+-----+			
Total	42	108	150
	28.00	72.00	100.00

```
. tab trat, gen(Trat)
```

trat	Freq.	Percent	Cum.
+-----+			
1	50	33.33	33.33
2	50	33.33	66.67
3	50	33.33	100.00
+-----+			
Total	150	100.00	

```
. logistic mejora Trat2 Trat3, nolog
```

Logistic regression	Number of obs	=	150
	LR chi2(2)	=	4.13
	Prob > chi2	=	0.1266
Log likelihood = -86.876173	Pseudo R2	=	0.0232

mejora	Odds Ratio	Std. Err.	z	P> z	[95% Conf. Interval]	
Trat2	1.744417	.7580485	1.28	0.200	.7443115	4.088329
Trat3	2.451613	1.123175	1.96	0.050	.9988146	6.017539

Regresión logística en diagnóstico y pronóstico

Desde el punto de vista estadístico, tanto el análisis diagnóstico como el pronóstico, se inscriben en el llamado análisis discriminante, esto es dadas dos muestras pertenecientes a poblaciones distintas y conocida esta pertenencia, determinar el conjunto de variables “descriptoras” (perfil del sujeto) que tiene capacidad de identificar cada una de las poblaciones a las que se hace referencia. Si la pertenencia a cada una de las poblaciones en cuestión la denotamos por los códigos “0 y 1” contenidos en la variable “Y”, para el perfil $X\beta$, podemos escribir:

$$P(Y = 1|X) = \frac{e^{X\beta}}{1 + e^{X\beta}}$$

Así, dado un perfil X, la idea es determinar si la estimación de probabilidad hecha por la distribución logística está cerca del 0 o cerca del 1. Esta decisión es posible tomarla si se escoge un punto de corte, “p” para la probabilidad estimada, de modo que si $P(Y = 1|X\beta) > p$, el sujeto será clasificado en la población “1”, de lo contrario el sujeto será clasificado en la población “0”. Con esta conceptualización, si la población de interés (enfermos, muertos, mejorías...) la llamamos “A” y la codificamos con “1”, definimos:

$S = P(Y=1 | X \in A)$: Sensibilidad de la discriminación .

$E = P(Y=0 | X \in A')$: Especificidad de la discriminación.

Obviamente que las probabilidades complementarias definen los sucesos “Falso Negativo” y “Falso Positivo”, respectivamente, es decir:

$P(Y=0 | X \in A) = 1-S$: Falso Negativo. (1-S)


$P(Y=1 | X \in A') = 1-E$: Falso Positivo. (1-E)

Como nuestro interés es tener buena capacidad de clasificación, es decir alta sensibilidad y alta especificidad. Lo que se traduce en:

$$P(Y=1 | X \in A) > P(Y=1 | X \in A')$$

$$S > 1-E$$


Si la discriminación fuera debida al azar se tendría $S=1-E$. Representando gráficamente estas relaciones, donde el eje de las abscisas es 1-E y el de las ordenadas S, se tiene:



Notar que si la discriminación fuese perfecta, es decir 100% de sensibilidad y 100% de especificidad, el punto de corte para la discriminación estaría en la intersección de las líneas azules y el área bajo la curva azul sería 1. Obviamente en cualquier aplicación real en que haya buena discriminación, esta área sería menor que 1 pero mayor a 0.5.

Observemos el siguiente ejemplo: Supongamos que la va X discrimina dos poblaciones, disponemos de 10 valores para la población "1" y 10 valores para la población "0", los datos son los siguientes:

Id	y	x
1	0	6
2	0	11
3	0	10
4	0	10
5	0	11
6	0	6
7	0	10
8	0	5
9	0	10
10	0	13
11	1	13
12	1	11
13	1	14
14	1	16
15	1	18
16	1	14
17	1	14
18	1	18
19	1	10
20	1	16



```
. logit y x, nolog
```

```
Logistic regression               Number of obs   =          20
                                LR chi2(1)        =          14.64
                                Prob > chi2         =          0.0001
Log likelihood = -6.5445675       Pseudo R2         =          0.5279
```

	y	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
	x	.9371287	.4217506	2.22	0.026	.1105127 1.763745
	_cons	-10.99978	4.905968	-2.24	0.025	-20.6153 -1.384262

$$P(y = 1|X) = \frac{e^{-10.99978+0.9371287 \cdot X}}{1 + e^{-10.99978+0.9371287 \cdot X}}$$


```
. predict p
(option pr assumed; Pr(y))
```

id	y	x	P(y=1 x)
1	0	6	0.004600
2	0	11	0.333729
3	0	10	0.164037
4	0	10	0.164037
5	0	11	0.333729
6	0	6	0.004600
7	0	10	0.164037
8	0	5	0.001807
9	0	10	0.164037
10	0	13	0.765467
11	1	13	0.765467
12	1	11	0.333729
13	1	14	0.892834
14	1	16	0.981912
15	1	18	0.997181
16	1	14	0.892834
17	1	14	0.892834
18	1	18	0.997181
19	1	10	0.164037
20	1	16	0.981912

La información anterior la podemos resumir en la siguiente tabla:

Pto. Corte	Número de sujetos ($y=1 Y=0$)	Número de sujetos ($y=1 Y=1$)	$P(y=1 Y=0)=1-E$	$P(y=1 Y=1)=S$
0.0018073	10	10	1.000	1.000
0.0046004	9	10	0.900	1.000
0.1640365	7	10	0.700	1.000
0.333729	3	9	0.300	0.900
0.7654671	1	8	0.100	0.800
0.8928338	0	7	0.000	0.700
0.9819124	0	4	0.000	0.400
0.9971809	0	2	0.000	0.200

Al graficar la sensibilidad versus 1-especificidad para los distintos puntos de corte se obtiene la curva ROC (Receiver Operating Characteristic).




Como se sugirió, la capacidad de discriminación está dada por el área bajo la curva ROC, que en nuestro caso es 0.9250. El mejor punto de corte es aquel que está más cerca de la discriminación perfecta.

Según Hosmer y Lemeshow ("Applied Logistic Regression" Second Edition, p. 162), la capacidad de discriminación puede clasificarse según:

Area bajo la curva ROC	Discriminación
0.5	por azar
0.7 a 0.8	aceptable
0.8 a 0.9	muy buena
0.9 a 1	excelente

Sin embargo, para encontrar el mejor punto de corte, es mejor usar el siguiente gráfico:



En STATA:

```
. logit y x, nolog
```

Logistic regression

```
Number of obs   =      20
LR chi2(1)      =     14.64
Prob > chi2     =     0.0001
Pseudo R2      =     0.5279
```

Log likelihood = -6.5445675

	y	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
	x	.9371287	.4217506	2.22	0.026	.1105127 1.763745
	_cons	-10.99978	4.905968	-2.24	0.025	-20.6153 -1.384262


```
. predict p
```

(option pr assumed; Pr(y))


```
. lroc
```

Logistic model for y

```
number of observations =      20
area under ROC curve   =     0.9250
```



. lsens



Recordando la definición de los Likelihood Ratios:

$$LR+ = \frac{P(y = 1|Y = 1)}{P(y = 1|Y = 0)} = \frac{\text{sensibilidad}}{1 - \text{especificidad}}$$

$$LR- = \frac{P(y = 0|Y = 1)}{P(y = 0|Y = 0)} = \frac{1 - \text{sensibilidad}}{\text{especificidad}}$$

Podemos leer a cabalidad la siguiente salida de STATA:

```
. roctab y p,d
```

Detailed report of Sensitivity and Specificity

Cutpoint	Sensitivity	Specificity	Correctly Classified	LR+	LR-
(>= .0018073)	100.00%	0.00%	50.00%	1.0000	
(>= .0046004)	100.00%	10.00%	55.00%	1.1111	0.0000
(>= .1640365)	100.00%	30.00%	65.00%	1.4286	0.0000
(>= .333729)	90.00%	70.00%	80.00%	3.0000	0.1429
(>= .7654671)	80.00%	90.00%	85.00%	8.0000	0.2222
(>= .8928338)	70.00%	100.00%	85.00%		0.3000
(>= .9819124)	40.00%	100.00%	70.00%		0.6000
(>= .9971809)	20.00%	100.00%	60.00%		0.8000
(> .9971809)	0.00%	100.00%	50.00%		1.0000

Obs	ROC Area	Std. Err.	-Asymptotic Normal-- [95% Conf. Interval]
20	0.9250	0.0575	0.81231 1.00000

Si se ha escogido como punto de corte 0.7654671:

```
. lstat, cutoff(.7654671)
```

Logistic model for y

Classified	True		Total
	D	~D	
+	8	1	9
-	2	9	11
Total	10	10	20

Classified + if predicted Pr(D) >= .7654671
True D defined as y != 0

Sensitivity	Pr(+ D)	80.00%
Specificity	Pr(- ~D)	90.00%
Positive predictive value	Pr(D +)	88.89%
Negative predictive value	Pr(~D -)	81.82%
False + rate for true ~D	Pr(+ ~D)	10.00%
False - rate for true D	Pr(- D)	20.00%
False + rate for classified +	Pr(~D +)	11.11%
False - rate for classified -	Pr(D -)	18.18%
Correctly classified		85.00%

Para encontrar el punto de corte de la variable original X, usamos:

$$\ln\left(\frac{p}{1-p}\right) = a + b \cdot X$$

De donde:

$$X = \frac{\ln\left(\frac{p}{1-p}\right) - a}{b}$$

En nuestro caso:

$$X = \frac{\ln\left(\frac{0.7654671}{1-0.7654671}\right) - (-10.99978)}{0.9371287} = 12.999997 = 13$$

```
. dis (ln(.7654671/(1-.7654671))-(-10.99978))/ .9371287
12.999997
```

