

La regresión logística: Una alternativa al análisis discriminante ante la ausencia de normalidad multivariante

Gabriel Cavada Chacón*

Luis Valverde Fallas**

Resumen

Tradicionalmente, la técnica para discriminar entre dos o más poblaciones a través de una colección de descriptores continuos es el Análisis Discriminante de Fisher, sin embargo cuando se relajan los supuestos en que descansa dicho análisis, persiste el uso de aquel. El objetivo de este trabajo es mostrar a través de algunos ejemplos, cómo la técnica de discriminación basada en la Regresión Logística discrimina mejor que el Análisis Discriminante de Fisher, mejorando ostensiblemente las proporciones de buena clasificación.

Palabras claves: Análisis Discriminante, Regresión Logística, Normalidad Multivariante.

* Ph.D. División de Bioestadística, Escuela de Salud Pública, Universidad de Chile. Académico, Escuela de Ingeniería, UCINF.

** Mg. Sc. Escuela de Matemáticas, Universidad de Costa Rica.

INTRODUCCIÓN

Como es sabido, la técnica para discriminar entre dos o más poblaciones, a través de una colección de descriptores continuos, es el Análisis Discriminante de Fisher. El método propuesto exige el supuesto de Normalidad Multivariante conjunta para el juego de variables predictoras y, si además se desea una función lineal discriminante, se debe agregar el supuesto de igualdad de matrices de covarianza para cada una de las poblaciones en estudio. Sin embargo, cuando se relaja el supuesto de Normalidad Multivariante, la tendencia es inclinarse nuevamente al Análisis Discriminante de Fisher, considerando la robustez del mismo.

El objetivo de este trabajo es mostrar, por medio de algunos ejemplos, que la Regresión Logística no sólo es una alternativa a tomar en cuenta, sino que, incluso, podría mejorar la capacidad de discriminación cuando no se cumplen los supuestos de Fisher. Cuando el juego de variables descriptoras sigue una distribución normal multivariante, los coeficientes de la Regresión Logística pueden ser estimados a través de la función lineal discriminante, pues se tiene la relación:

$$\beta_0 = \ln\left(\frac{p}{1-p}\right) - \frac{1}{2}\beta(\mu_1 + \mu_0)$$

donde p es la probabilidad de pertenecer a la población 1, $1-p$ la probabilidad de pertenecer a la población 0 y $\beta = (\mu_1 - \mu_0)' \Sigma^{-1}$ que es el vector de coeficientes de la función lineal discriminante (Hosmer y Lemeshow, 1989). Es decir, cuando los supuestos de Fisher se cumplen, discriminar a través de la Regresión Logística y de la Función Lineal Discriminante es equivalente.

Si no se cumplen los supuestos de Fisher, no es posible encontrar relaciones entre ambos procedimientos y, como se planteó al inicio, la tendencia es usar la Función Lineal Discriminante, debido a la robustez de dicho método. Sin embargo, en las condiciones expuestas, la experiencia con algunas bases de datos es que la Regresión Logística entrega mayores porcentajes de buena clasificación.

RESULTADOS

Como primer ejemplo ilustrativo se presenta la propuesta metodológica aplicada a los clásicos datos de Fisher, referentes a las flores de Iris (1936) (SAS, 1997):

- Estadísticas descriptivas de las variables descriptoras desagregadas por especie:


-> clase= SETOSA					
Variable	Obs	Mean	Std. Dev.	Min	Max
sepalen	50	50.06	3.524897	43	58
sepalwid	50	34.28	3.790644	23	44
petallen	50	14.62	1.73664	10	19
petalwid	50	2.46	1.053856	1	6
-> clase= VERSICOL					
Variable	Obs	Mean	Std. Dev.	Min	Max
sepalen	50	59.36	5.161711	49	70
sepalwid	50	27.7	3.137983	20	34
petallen	50	42.6	4.69911	30	51
petalwid	50	13.26	1.977527	10	18
-> clase= VIRGINIC					
Variable	Obs	Mean	Std. Dev.	Min	Max
sepalen	50	65.88	6.358796	49	79
sepalwid	50	29.74	3.224966	22	38
petallen	50	55.52	5.518947	45	69
petalwid	50	20.26	2.746501	14	25

- Dócima de Shapiro-Wilk para probar la normalidad de datos:

Shapiro-Wilk W test for normal data					
Variable	Obs	W	V	z	Pr > z
sepalen	150	0.97940	2.397	1.981	0.02377
sepalwid	150	0.99098	1.049	0.108	0.45682
petallen	150	0.88019	13.940	5.973	0.00000
petalwid	150	0.92197	9.079	5.001	0.00000

los p-value en negrita muestran el no cumplimiento del supuesto de normalidad multivariante de los datos. Usando análisis de componentes principales, graficando los dos primeros puntajes principales, se expone el

traslape de las especies Versicolor y Virgínica, las que posteriormente serán discriminadas por el método de la Función Lineal Discriminante y de Regresión Logística para comparar su capacidad de discriminación:



Donde 1: Setosa, 2: Versicolor y 3: Virgínica

Para proceder a comparar los métodos de discriminación, se recodificaron las variables para las especies Versicolor y Virgínica con 0 y 1, respectivamente, dejando fuera del análisis la especie Setosa.

En estas condiciones, el Análisis Discriminante de Fisher entrega la siguiente tabla de clasificación:

Clasif.	clase		Total
	Versicolor	Virgínica	
Mal	4 8.00%	3 6.00%	7 7.00%
Bien	46 92.00%	47 94.00%	93 93.00%
Total	50 100.00%	50 100.00%	100 100.00%

Es decir, para la clase Versicolor se clasifica correctamente el 92% de las flores, para la clase Virgínica se clasifica correctamente el 94% de las flores, generándose un total de buena clasificación de 93%.

Al discriminar con la Regresión Logística se obtiene la siguiente tabla de clasificación:

LOGISTIC MODEL FOR ESPECIE

Classified	True		Total
	D	~D	
+	49	1	50
-	1	49	50
Total	50	50	100
Classified + if predicted $\Pr(D) \geq .5$ True D defined as espe $\sim = 0$			
Sensitivity	$\Pr (+ D)$		98.00%
Specificity	$\Pr (- \sim D)$		98.00%
Positive predictive value	$\Pr (D +)$		98.00%
Negative predictive value	$\Pr (\sim D -)$		98.00%
False + rate for true ~D	$\Pr (+ \sim D)$		2.00%
False - rate for true D	$\Pr (- D)$		2.00%
False + rate for classified +	$\Pr (\sim D +)$		2.00%
False - rate for classified -	$\Pr (D -)$		2.00%
Correctly classified			98.00%

Se observa que para la clase Versicolor se clasifica correctamente el 98% de las flores, para la clase Virgínica también se clasifica correctamente el 98% de las flores, resultando un total de buena clasificación de 98%. En el ejemplo analizado se advierte que la Regresión Logística aumenta la buena clasificación de 93% a un 98%.

Un segundo ejemplo discrimina, basándose en seis variables descriptoras, entre dos grupos: veinte aprendices de ingeniero y veinte pilotos (Rencher, 1995). La variable grupo está codificada como 0: aprendiz de ingeniero y 1: piloto. Las seis variables descriptoras son: y_1 : intelligent, y_2 : form relation, y_3 : dynamometer, y_4 : dotting, y_5 : sensory motor coordination y y_6 : perseveration. En este contexto se tiene que:

- Estadísticas descriptivas de las variables descriptoras desagregadas por grupo:


-> clase= 0					
Variable	Obs	Mean	Std. Dev.	Min	Max
y1	20	124.5	19.60263	77	154
y2	20	38.1	8.258329	21	55
y3	20	76.2	11.00526	52	91
y4	20	192.75	31.6259	152	266
y5	20	53.65	17.95689	29	88
y6	20	250.3	21.68458	209	300
-> clase= 1					
Variable	Obs	Mean	Std. Dev.	Min	Max
y1	20	129.3	26.22594	47	164
y2	20	31.7	7.189905	17	47
y3	20	87.4	10.53016	67	105
y4	20	236.6	28.15259	183	291
y5	20	44.25	13.17843	27	66
y6	20	280.2	35.4083	217	324

- Décima de Shapiro-Wilk para probar la normalidad de datos:

Shapiro-Wilk W test for normal data					
Variable	Obs	W	V	z	Pr > z
y1	40	0.92914	2.801	2.168	0.01510
y2	40	0.98409	0.629	-0.977	0.83560
y3	40	0.98188	0.716	-0.702	0.75861
y4	40	0.96838	1.250	0.469	0.31950
y5	40	0.93884	2.418	1.858	0.03161
y6	40	0.93684	2.497	1.926	0.02708

Nuevamente, los p-value en negrita descartan la Normalidad Multivariante de los datos. A partir de un análisis de componentes principales, se genera un gráfico con los dos primeros pun-

tajes principales, donde se muestra el traslape de los grupos en estudio. Procedemos entonces a discriminar por el método de la Función Lineal Discriminante y el de Regresión Logística:



Donde 0: aprendiz de ingeniero y 1: piloto

Al realizar Análisis Discriminante, se encuentra la siguiente tabla de clasificación:

Clasif.	clase		Total
	0	1	
Mal	3 15.00	3 15.00	6 15.00
Bien	17 85.00	17 85.00	34 85.00
Total	20 100.00	20 100.00	40 100.00

El Análisis Discriminante de Fisher proporciona en este caso un 85% de buena clasificación en ambos grupos y también un 85% de buena clasificación en el total de los casos.

Por otra parte, la Regresión Logística entrega la siguiente tabla de clasificación:

LOGISTIC MODEL FOR CLASE

Classified	True		Total
	D	~D	
+	18	2	20
-	2	18	20
Total	20	20	40
Classified + if predicted $\Pr(D) \geq .5$ True D defined as class $\sim = 0$			
Sensitivity	$\Pr(+ D)$		90.00%
Specificity	$\Pr(- \sim D)$		90.00%
Positive predictive value	$\Pr(D +)$		90.00%
Negative predictive value	$\Pr(\sim D -)$		90.00%
False + rate for true ~D	$\Pr(+ \sim D)$		10.00%
False - rate for true D	$\Pr(- D)$		10.00%
False + rate for classified +	$\Pr(\sim D +)$		10.00%
False - rate for classified -	$\Pr(D -)$		10.00%
Correctly classified			90.00%

El resultado anterior muestra que la buena clasificación mejora nuevamente con la Regresión Logística, en un 5% para cada grupo y en igual porcentaje para el total de los datos.

CONCLUSIÓN

A través de los ejemplos analizados se ha dado cuenta de que la técnica de discriminación a través de la Re-

gresión Logística, cuando el supuesto de Normalidad Multivariante no se satisface, puede mejorar significativamente la capacidad de discriminación de los datos; aunque, si bien lo expuesto no es generalizable, nuestro planteamiento es que la Regresión Logística debería considerarse como una alternativa para mejorar la discriminación ante la carencia de algunos de los supuestos de Fisher.

BIBLIOGRAFÍA

FISHER, R.A. "The Use of Multiple Measurement in Taxonomic Problems". *Annals of Eugenics* 7 (1936): 179-84.

HOSMER, DAVID and STANLEY LEMESHOW. *Applied Logistic Regression*. New York: John Wiley & Sons, 1989.

SAS *User's Guide*. Chapell Hill, North Carolina: SAS Institute Inc., 1997.

RENCHER, ALVIN. *Method of Multivariate Analysis*. New York: John Wiley & Sons, 1995.