

Curvas R.O.C.

Carlos Carleos Norberto Corral

Departamento de Estadística
e Investigación Operativa
y de Didáctica de la Matemática
Universidad de Oviedo

8 de noviembre de 2021


Origen

Receiver Operating Characteristic (ROC)

- ▶ Proviene de la teoría de detección de señales (discernir entre señal y ruido)
- ▶ Gráfico estadístico
- ▶ Ayuda a definir un umbral de separación entre dos grupos
 - ▶ Positivos (los que verifican cierta condición)
 - ▶ Negativos (los que no la cumplen)

Ejemplo

Señal en radar: ¿ruido o **aviones**?



Umbral de detección (decidir entre “ruido” o “**avión**”)

- ▶ **umbral alto**
no se detectan objetos reales (Falsos Negativos)
- ▶ **umbral bajo**
muchos avisos falsos (Falsos Positivos)

Estado

El estado indica el grupo al que realmente pertenece cada individuo.

- ▶ Variable aleatoria D que toma los valores

$$D = \begin{cases} 0 & \text{No verifica la condición (Negativo)} \\ 1 & \text{Si verifica la condición (Positivo)} \end{cases}$$

- ▶ $D \rightsquigarrow \text{Bernoulli}(p)$

$$p = \Pr(D = 1) = \Pr(\text{Positivo}) = \text{prevalencia}$$

$$1 - p = \Pr(D = 0) = \Pr(\text{Negativo})$$

Variable medida

- ▶ X representa a la variable que se usa para establecer el criterio de clasificación
 - ▶ En los Positivos $X = X_P = (X | D = 1)$
 - ▶ En los Negativos $X = X_N = (X | D = 0)$
- ▶ Sus correspondientes funciones de distribución son
 - ▶ $F_P(x) = \Pr(X_P \leq x)$
 - ▶ $F_N(x) = \Pr(X_N \leq x)$

Variable criterio de clasificación

Cuando X tiende a tomar valores mayores para los individuos positivos la clasificación se suele asociar a alcanzar cierto umbral c :

$$Y = \begin{cases} 1 \text{ (Positivo)} & \text{si } X \geq c \\ 0 \text{ (Negativo)} & \text{si } X < c \end{cases}$$

Estimador de la prevalencia

- ▶ Proporción muestral

$$p = \frac{\text{número de individuos Positivos de la muestra}}{\text{número de individuos de la muestra}}$$

- ▶ En algunos tipos de muestreo, por ejemplo caso-control, no es una buena estimación.

Términos habituales

VP	verdadero positivo	\iff	$D = 1, Y = 1$
FP	falso positivo	\iff	$D = 0, Y = 1$
FN	falso negativo	\iff	$D = 1, Y = 0$
VN	verdadero negativo	\iff	$D = 0, Y = 0$

Sensibilidad

- ▶ Probabilidad de acertar al clasificar un individuo positivo

$$S = \Pr(Y = 1 | D = 1) = \frac{\Pr(Y = 1 \cap D = 1)}{\Pr(D = 1)}$$

$$S = \Pr(X_p \geq c)$$

$$\hat{S} = \frac{VP}{VP + FN} = \text{fracción de verdaderos positivos} = FVP$$

$$1 - \hat{S} = \frac{FN}{VP + FN} = \text{fracción de falsos negativos} = FFN$$

Especificidad

- ▶ Probabilidad de acertar al clasificar un individuo negativo

$$E = \Pr(Y = 0 | D = 0) = \frac{\Pr(Y = 0 \cap D = 0)}{\Pr(D = 0)}$$

$$E = \Pr(X_n < c)$$

$$\hat{E} = \frac{VN}{VN + FP} = \text{fracción de verdaderos negativos} = FVN$$


$$1 - \hat{E} = \frac{FP}{VN + FP} = \text{fracción de falsos positivos} = FFP$$

Valores predictivos

- ▶ Valor predictivo positivo (Probabilidad a posteriori)
 - ▶ $\Pr(D = 1 | Y = 1)$
 - ▶ Se estima mediante $\widehat{VPP} = \frac{VP}{VP + FP}$
- ▶ Valor predictivo negativo (Probabilidad a posteriori)
 - ▶ $\Pr(D = 0 | Y = 0)$
 - ▶ Se estima mediante $\widehat{VPN} = \frac{VN}{VN + FN}$

Definición de curva ROC


Ejemplo: Diagnosticar una enfermedad teniendo en cuenta la temperatura.



$$Y = \begin{cases} 1 \text{ (Positivo)} & \text{temperatura} \geq c \\ 0 \text{ (Negativo)} & \text{temperatura} < c \end{cases}$$

Definición de curva ROC

Objetivo: Elegir c que tenga la Sensibilidad y la Especificidad altas.



Definición de curva ROC

La curva ROC representa, para cada valor del umbral la Sensibilidad frente a 1-Especificidad, es decir,

- ▶ Abscisas: 1-Especificidad= $\Pr(\text{Error} | D=0)$
- ▶ Ordenadas: Sensibilidad= $\Pr(\text{Acierto} | D=1)$

Suponiendo que X toma, en general, valores mayores para los positivos y un umbral x , se tiene:

$$t = 1 - E(x) = \Pr(Y(x) = 1 | D = 0) = 1 - F_N(x)$$


$$x = F_N^{-1}(1 - t)$$

$$ROC(t) = \Pr(\text{Acierto} | \text{Positivo}) = S(x) = 1 - F_P(x)$$

$$ROC(t) = 1 - F_P(F_N^{-1}(1 - t)) \quad 0 \leq t \leq 1$$

Definición de curva ROC

CURVA ROC



Método no paramétrico para estimar la curva ROC

- ▶ Usa la función de distribución empírica asociada a la muestra:

$$\hat{F}_P(x) = \frac{n(x_i \leq x \mid \text{Positivos})}{n_P}$$


$$\hat{F}_N(x) = \frac{n(x_i \leq x \mid \text{Negativos})}{n_N}$$

- ▶ Se define la curva ROC empírica como

$$\widehat{ROC}(t) = 1 - \hat{F}_P(\hat{F}_N^{-1}(1-t))$$

- ▶ Este procedimiento da lugar a una curva ROC escalonada

Método no paramétrico para estimar la curva ROC



Método paramétrico para estimar la curva ROC

- ▶ Modelo binormal
 - ▶ $(X_P \rightsquigarrow N(\mu_P, \sigma_P))$ Positivos
 - ▶ $X_N \rightsquigarrow N(\mu_N, \sigma_N)$ Negativos
- ▶ La curva ROC en el modelo binormal es

$$ROC(t) = 1 - \Phi\left(\frac{\mu_N - \mu_P + \sigma_N \cdot \Phi^{-1}(1-t)}{\sigma_P}\right) \quad 0 \leq t \leq 1$$

$$= \Phi\left(\frac{\mu_P - \mu_N + \sigma_N \cdot \Phi^{-1}(t)}{\sigma_P}\right) = \Phi(\alpha + \beta \cdot \Phi^{-1}(t))$$

$$\text{donde } \alpha = \frac{\mu_P - \mu_N}{\sigma_P}, \beta = \frac{\sigma_N}{\sigma_P},$$

Φ = función de distribución de la gausiana típica

Método paramétrico para estimar la curva ROC

- ▶ La curva ROC estimada es


$$\widehat{ROC}(t) = 1 - \Phi(\hat{\alpha} + \hat{\beta} \cdot \Phi^{-1}(t)) \quad 0 \leq t \leq 1$$

donde

$$\hat{\alpha} = \frac{\hat{\mu}_P - \hat{\mu}_N}{\hat{\sigma}_P} \quad \hat{\beta} = \frac{\hat{\sigma}_N}{\hat{\sigma}_P}$$

- ▶ Es una curva suave y derivable en todos los puntos.

Método paramétrico para estimar la curva ROC



Precisión o exactitud de un clasificador

$$\begin{aligned}\Pr(\text{acertar}) &= \Pr(Y = 1 | D = 1) \cdot \Pr(D = 1) \\&\quad + \Pr(Y = 0 | D = 0) \cdot \Pr(D = 0) \\&= S \cdot \Pr(D = 1) + E \cdot \Pr(D = 0)\end{aligned}$$

- ▶ Estimador

$$\widehat{\Pr}(\text{acertar}) = \frac{VP + VN}{n} = \frac{\text{resultados acertados}}{\text{total de la muestra}}$$

- ▶ Proporción de aciertos en la clasificación sin distinguir positivos de negativos
- ▶ Es necesario conocer o estimar la prevalencia $\Pr(D = 1)$

Área bajo la curva

El Área Bajo la Curva AUC (*area under curve*) se define así:

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

$$AUC = P(X_P > X_N)$$

Demostración:

$$AUC = \int_0^1 ROC(t) dt = \int_0^1 [1 - F_p(F_N^{-1}(1-t))] dt$$

Haciendo el cambio de variable $u = F_N^{-1}(1-t)$ se tiene $F_N(u) = 1 - t \iff t = 1 - F_N(u)$.

$$\begin{aligned} \text{Por tanto } dt &= -f_N(u)du \text{ y la integral anterior es} \\ \int_{-\infty}^{\infty} (1 - F_p(u))f_N(u) du &= 1 - \int_{-\infty}^{\infty} F_p(u)f_N(u) du = \\ 1 - \int_{-\infty}^{\infty} \left(\int_{-\infty}^v f_p(v) dv \right) f_N(u) du &= 1 - P(X_p \leq X_N) = \\ P(X_p > X_N) \end{aligned}$$

Área bajo la curva

Propiedades del Área Bajo la Curva AUC:

- ▶ $AUC = P(X_P > X_N)$
- ▶ $0,5 \leq AUC \leq 1$
- ▶ $AUC \approx 0,5 \iff$ poca capacidad de discriminación
- ▶ $AUC \approx 1 \iff$ separación casi total
- ▶ Se usa con mucha frecuencia para medir la capacidad de una variable para separar dos poblaciones

Métodos para calcular el AUC

- Método no paramétrico (regla trapezoidal)

$$\widehat{AUC} = \sum_{t=1}^T \frac{1}{2} (FFP_t - FFP_{t-1}) \cdot (FVP_t + FVP_{t-1})$$

- Método paramétrico (caso binormal)

$$\begin{aligned}\widehat{AUC} &= \int_0^1 \widehat{ROC}(t) dt = \int_0^1 \left(1 - \Phi[\hat{\alpha} + \hat{\beta} \cdot \Phi^{-1}(1-t)] \right) dt \\ &= \Phi\left(\frac{\hat{\alpha}}{\sqrt{1+\hat{\beta}^2}}\right) = \Phi\left(\frac{\hat{\mu}_N - \hat{\mu}_P}{\sqrt{\hat{\sigma}_N^2 + \hat{\sigma}_P^2}}\right)\end{aligned}$$

Comparación de dos curvas ROC

- ▶ Contraste

$$H_0 : AUC_1 = AUC_2$$

$$H_1 : AUC_1 \neq AUC_2$$

- ▶ Estadístico

$$z = \frac{\widehat{AUC}_1 - \widehat{AUC}_2}{ET(\widehat{AUC}_1 - \widehat{AUC}_2)}$$

Criterios para elegir el punto de corte

- ▶ Método 1. El índice de Youden
- ▶ Método 2. Buscar el punto $(1-E; S)$ sobre la curva ROC más cercano al punto $(0;1)$.


Índice de Youden

- ▶ Busca el umbral que hace máxima la suma de la sensibilidad y la especificidad

$$\begin{aligned} J &= \Pr(Y = 1 | D = 1) + \Pr(Y = 0 | D = 0) - 1 \\ &= \text{Sensibilidad} + \text{Especificidad} - 1 \end{aligned}$$

- ▶ $0 \leq J \leq 1$
- ▶ $J \approx 0 \iff$ discrimina poco entre positivos y negativos
- ▶ $J \approx 1 \iff$ discrimina mucho entre positivos y negativos
- ▶ Su estimador se define como $\hat{J} = FVP - FFP$

Índice de Youden



Punto de corte: método 2

- ▶ Buscar el punto $(1-E; S)$ sobre la curva ROC más cercano al punto $(0;1)$.
El umbral que se elige está asociado al punto sobre la curva que hace mínima la siguiente expresión:

$$(1 - Especificidad)^2 + (1 - Sensibilidad)^2$$

Biblioteca «pROC»

```
nnN <- nP <- 50 # tamaño de la muestra
# simulación de los datos de la variable X1
N1 <- rnorm (nnN, 36, 0.8) # negativos
P1 <- rnorm (nP, 38, 0.8) # positivos
# install.packages ("pROC") # instalar la librería
library (pROC) # carga la librería pROC
C1 <- roc(controls=N1,cases=P1) # curva ROC C1
plot (C1, legacy.axes=TRUE) # gráfica de la curva
auc (C1)      # área bajo la curva
ci(C1) ## Intervalo confianza AUC
```

Biblioteca «pROC»

```
# criterios para elegir el umbral
## método 1: Youden
coords(C1,"best")
# método 2
coords(C1,"best",best.method="closest.topleft")

# simulación de los datos de la variable X2
N2 <- rnorm (nN, 36.5, 0.8) # negativos
P2 <- rnorm (nP, 37.5, 0.8) # positivos
C2 <- roc(controls=N2,cases=P2) # curva ROC 2

# gráfica con las dos curvas
plot (C2, add=TRUE, col="red")

roc.test (C1, C2) # compara las curvas C1 y C2
```