

CORvas

Curvas R.O.C.

Carlos Carleos Norberto Corral

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

Máster de Análisis de Datos
para Inteligencia de Negocios

Partes

1 Teoría

- Motivación, conceptos previos y definición
- Inferencia
- Elección del umbral


2 Práctica en R

Origen

- Gráfico estadístico
- Ayuda a definir un umbral de clasificación entre dos grupos
 - Positivos (los que verifican cierta condición)
 - Negativos (los que no la cumplen)
- C.O.R. = característica operativa del receptor
- Proviene de la teoría de detección de señales
(discernir entre señal y ruido)

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)

Objetivo

- umbral de detección
 - **umbral alto**
no se detectan objetos reales (Falsos Negativos)
 - **umbral bajo**
muchos avisos falsos (Falsos Positivos)
- Es conveniente buscar un valor que equilibre ambas opciones.
- La curva ROC ayuda a buscar un umbral que haga poco frecuentes ambos tipos de clasificaciones erróneas.

Estado

- Grupo al que realmente pertenece cada individuo
- Variable aleatoria D que toma los valores

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

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

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

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

Variable medida

- 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

- Toma dos valores posibles en función del valor de X

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

Estimador de la prevalencia

- Proporción muestral

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

- Depende del tipo de muestreo

Términos habituales

| | | |
|----|--------------------|----------------|
| VP | verdadero positivo | $D = 1, Y = 1$ |
| FP | falso positivo | $D = 0, Y = 1$ |
| FN | falso negativo | $D = 1, Y = 0$ |
| VN | verdadero negativo | $D = 0, Y = 0$ |

| | | Y=1 | Y=0 |
|-----|----|-----|-----|
| D=1 | VP | FN | |
| | FP | VN | |

Sensibilidad

- Probabilidad de acertar en la clasificación de un individuo positivo

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

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

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

Especificidad

- Probabilidad de acertar en la clasificación de un individuo negativo

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

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

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

Fracciones (tabla resumen)

| | Y=1 | Y=0 | suma |
|-----|-----|-----|------|
| D=1 | FVP | FFN | 1 |
| D=0 | FFP | FVN | 1 |

Valores predictivos

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

Definición de curva ROC

- **Curva ROC poblacional**
- Gráfica que representa, para cada posible valor del umbral c , la Sensibilidad frente a $1 - \text{Especificidad}$, es decir,
 - Abscisas = $1 - \text{Especificidad}$
 - Ordenadas = Sensibilidad
- Suponiendo que X toma, en general, valores mayores para los positivos,

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

donde

- $t = 1 - E(x) = \Pr(Y(x) = 1 \mid D = 0) = 1 - F_N(x) = \Pr(\text{Error} \mid \text{Negativo } D = 0)$
- $ROC(t) = S(x) = 1 - F_P(x) = \Pr(\text{Acierto} \mid \text{Positivo } D = 1)$

Método no paramétrico para estimar la curva ROC

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

$$\hat{F}_P(x) = \frac{\text{nº}(x_i \leq x \mid \text{Positivos})}{n_P}$$


$$\hat{F}_N(x) = \frac{\text{nº}(x_i \leq x \mid \text{Negativos})}{n_N}$$

- Se define la curva ROC empírica como

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

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

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

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

Φ = función de distribución de la gausiana típica

Método paramétrico para estimar la curva ROC

- La curva ROC estimada es


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

donde

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

- Tiene un aspecto liso

Método no paramétrico para estimar la curva ROC



Contrastes de hipótesis

- En el caso concreto del modelo binomial

$$H_0 : \alpha_1 = \alpha_2 \cap \beta_1 = \beta_2$$

$$H_1 : \alpha_1 \neq \alpha_2 \cup \beta_1 \neq \beta_2$$

- El estadístico del contraste:

$$\chi^2 = \frac{\hat{\alpha}_{12} \cdot \hat{V}(\hat{\beta}_{12}) + \hat{\beta}_{12} \cdot \hat{V}(\hat{\alpha}_{12}) - 2 \cdot \hat{\alpha}_{12} \cdot \hat{\beta}_{12} \cdot \widehat{\text{cov}}(\hat{\alpha}_{12}, \hat{\beta}_{12})}{\hat{V}(\hat{\alpha}_{12}) \cdot \hat{V}(\hat{\beta}_{12}) - \widehat{\text{cov}}(\hat{\alpha}_{12}, \hat{\beta}_{12})}$$

donde $\hat{\alpha}_{12} = \hat{\alpha}_1 - \hat{\alpha}_2$ y $\hat{\beta}_{12} = \hat{\beta}_1 - \hat{\beta}_2$

- Asintóticamente bajo H_0 , $\chi^2 \rightsquigarrow \chi^2_2$

Precisión o exactitud de un clasificador

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

- Estimador $\hat{\Pr}(\text{acertar}) = \frac{VP + VN}{n} = \frac{\text{resultados acertados}}{\text{total de la muestra}}$
- Proporción de aciertos en la clasificación sin distinguir positivos de negativos


Índice de Youden

- Es la diferencia entre las probabilidades de la respuesta positiva correcta y de la respuesta positiva incorrecta

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

- $0 \leq J \leq 1$
- $J \approx 0 \iff$ 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



Área bajo la curva

- AUC (*area under curve*) se define así:

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

- $0,5 \leq AUC \leq 1$
- $AUC \approx 0,5 \iff$ 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 pruebas

- Contraste

$$H_0 : AUC_1 = AUC_2$$

$$H_1 : AUC_1 \neq AUC_2$$

- Estadístico

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

Aleatoriedad de la prueba

- Contraste

$$H_0 : AUC = 0,5$$


$$H_1 : AUC \neq 0,5$$

- Estadístico

$$z = \frac{\widehat{AUC} - 0,5}{ET(\widehat{AUC})}$$

Punto de corte: método 1

- Usar el umbral correspondiente al índice de Youden



Punto de corte: método 2

- Buscar el punto $(1-E; S)$ sobre la curva ROC más cercano al punto $(0;1)$
- La pendiente sobre ese punto vale

$$m = \frac{p \cdot \Pr(\text{falsos positivos})}{(1 - p) \cdot \Pr(\text{falsos negativos})}$$

siendo p la prevalencia del evento en la población

Punto de corte: método 3

- En este caso se tienen en cuenta los costes de los dos tipos de error
- Buscar el punto $(1-E; S)$ sobre la curva ROC más cercano al que minimiza dichos costes
- La pendiente sobre ese punto vale

$$m = \frac{\text{costes falsos positivos} \cdot (1 - p)}{\text{costes falsos negativos} \cdot p}$$

siendo p la prevalencia del evento en la población

Implementación ingenua

```
nN <- nP <- 50                                # tamaños
N <- rnorm (nN, 0, 1)                            # negativos
P <- rnorm (nP, 1, 1)                            # positivos
t <- sort (union (N, P))                         # todos
U <- c (-Inf, t[-1]-diff(t)/2, Inf)             # umbrales
s <- sapply (U,                                     # sensibilidad
             function (Ui)
               sum (P > Ui) / nP)
e <- 1 - sapply (U,                               # 1 - especificidad
                 function (Ui)
                   sum (N <= Ui) / nN)
o <- order (e, s)                                # 's' rompe empates
plot (e[o], s[o], type="s")                      # "s" para peldaños
```

Implementación mediante «ecdf»

```
nN <- nP <- 50 # tamaños
N <- rnorm (nN, 0, 1) # negativos
P <- rnorm (nP, 1, 1) # positivos
C <- 1 - ecdf (P) (sort (N, decreasing=TRUE)) # CORva
plot (seq (0, 1, length.out=nN), C, type="s")
```

Biblioteca «pROC»

```
nN <- nP <- 50                                # tamaños
N <- rnorm (nN, 0, 1)                            # negativos
P <- rnorm (nP, 1, 1)                            # positivos
install.packages ("pROC")
library (pROC)
C <- roc (controls = N, cases = P)              # CORva
plot (C)
auc (C)                                         # área bajo la curva
ci (C)                                          # intervalo de confianza
roc.test (C1, C2)      # para comparar dos CORvas
```

Biblioteca «pROC»: mejor umbral

```
plot (C)

## mejor umbral según método 1 (Youden)
uY <- coords (C, "best")
uY <- coords (C, "best", best.method = "youden") # ídem
abline (v = uY["specificity"], col = 2)           # rojo

## mejor umbral según método 2 (cercano a la esquina)
uC <- coords (C, "best", best.method="closest.topleft")
abline (v = uC["specificity"], col = 3)           # verde

## para método 3, la opción «best.weights»
## permite dar los dos coeficientes de costes
```

Biblioteca «nsROC»

```
nN <- nP <- 50                                # tamaños
N <- rnorm (nN, 0, 1)                            # negativos (controles)
P <- rnorm (nP, 1, 1)                            # positivos (casos)

install.packages ("nsROC")                      # © Sonia Pérez
library (nsROC)                                # Dptº Estadística, UO

X <- c (N, P)                                    # marcador
D <- c (rep (0, nN), rep(1, nP))      # 0=control 1=caso

gROC (X, D, plot.roc = TRUE, plot.density = TRUE)
```