

Tema 5: Evaluación de Modelos de Clasificación Supervisada

Pedro Larrañaga, Iñaki Inza, Abdelmalik Moujahid

Departamento de Ciencias de la Computación e Inteligencia Artificial

Universidad del País Vasco

<http://www.sc.ehu.es/isg/>

Evaluación de Modelos de Clasificación Supervisada

- Introducción
- Estimación de la probabilidad de clasificación correcta
- Brier score
- La curva ROC

Introducción

Clasificación Supervisada

	X_1	\dots	X_n	C
$(\mathbf{x}^{(1)}, c^{(1)})$	$x_1^{(1)}$	\dots	$x_n^{(1)}$	$c^{(1)}$
$(\mathbf{x}^{(2)}, c^{(2)})$	$x_1^{(2)}$	\dots	$x_n^{(2)}$	$c^{(2)}$
\dots		\dots		\dots
$(\mathbf{x}^{(N)}, c^{(N)})$	$x_1^{(N)}$	\dots	$x_n^{(N)}$	$c^{(N)}$
$\mathbf{x}^{(N+1)}$	$x_1^{(N+1)}$	\dots	$x_n^{(N+1)}$???

Introducción

Clasificación Supervisada

	X_1	\dots	X_n	C	C_M
$(\mathbf{x}^{(1)}, c^{(1)})$	$x_1^{(1)}$	\dots	$x_n^{(1)}$	$c^{(1)}$	$c_M^{(1)}$
$(\mathbf{x}^{(2)}, c^{(2)})$	$x_1^{(2)}$	\dots	$x_n^{(2)}$	$c^{(2)}$	$c_M^{(2)}$
\dots		\dots		\dots	\dots
$(\mathbf{x}^{(N)}, c^{(N)})$	$x_1^{(N)}$	\dots	$x_n^{(N)}$	$c^{(N)}$	$c_M^{(N)}$

Número de aciertos: $\sum_{i=1}^N \delta(c^{(i)}, c_M^{(i)})$


$$\delta(c^{(i)}, c_M^{(i)}) = \begin{cases} 1 & \text{si } c^{(i)} = c_M^{(i)} \\ 0 & \text{si } c^{(i)} \neq c_M^{(i)} \end{cases}$$

Introducción

		C Clase real	
		+	-
		<hr/>	
	+	a	b
C_M Clase predicha	-	c	d
		<hr/>	

- Tasa de acierto: $\frac{a+d}{a+b+c+d}$
- Tasa de error: $\frac{c+b}{a+b+c+d}$
- Proporción de verdaderos positivos (sensibilidad): $\frac{a}{a+c}$
- Proporción de verdaderos negativos (especificidad): $\frac{d}{b+d}$
- Proporción de falsos positivos: $\frac{b}{a+c}$
- Proporción de falsos negativos: $\frac{c}{b+d}$

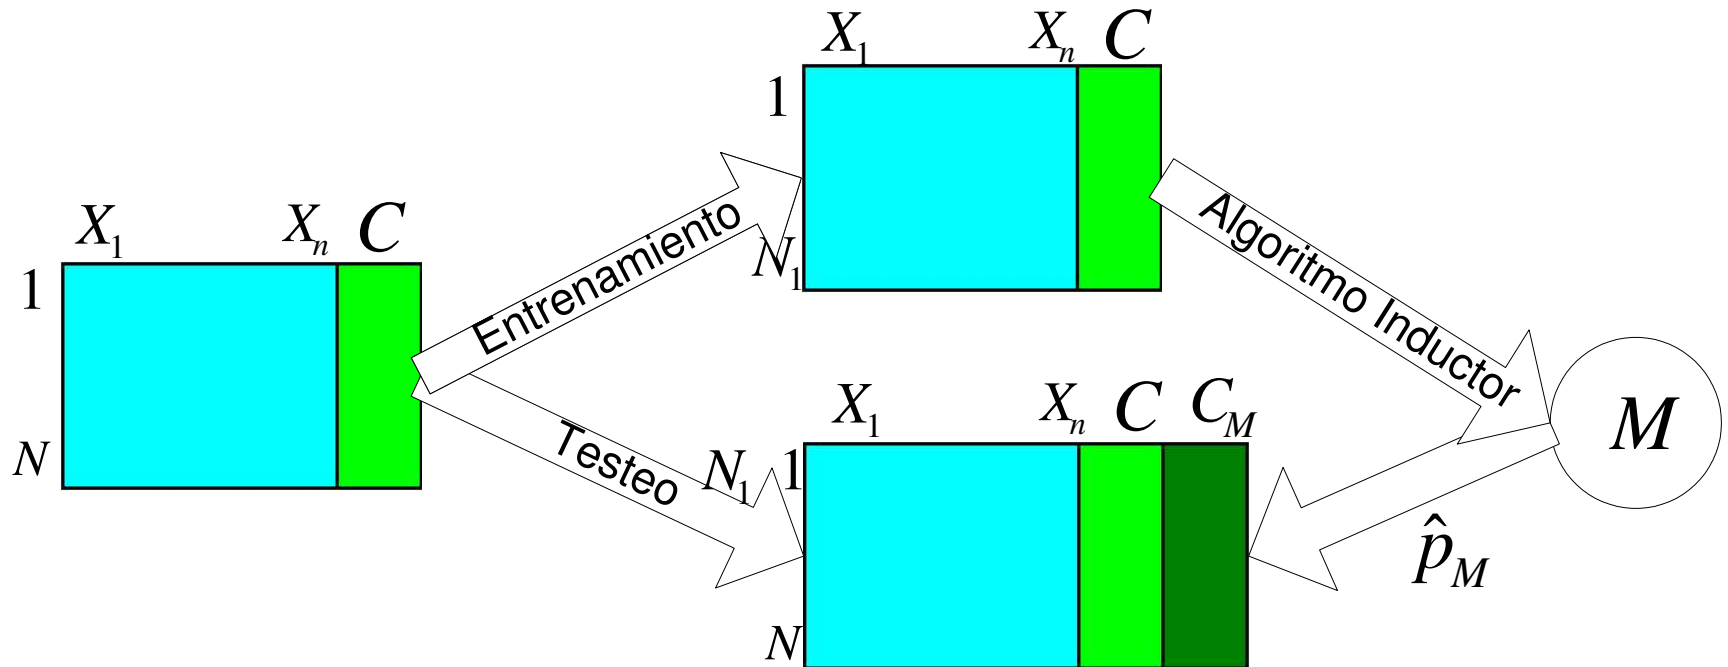
Estimación de la probabilidad de clasificación correcta



$$\hat{p}_M = \frac{1}{N} \sum_{i=1}^N \delta(c^{(i)} = c_M^{(i)})$$

Método no honesto de estimación

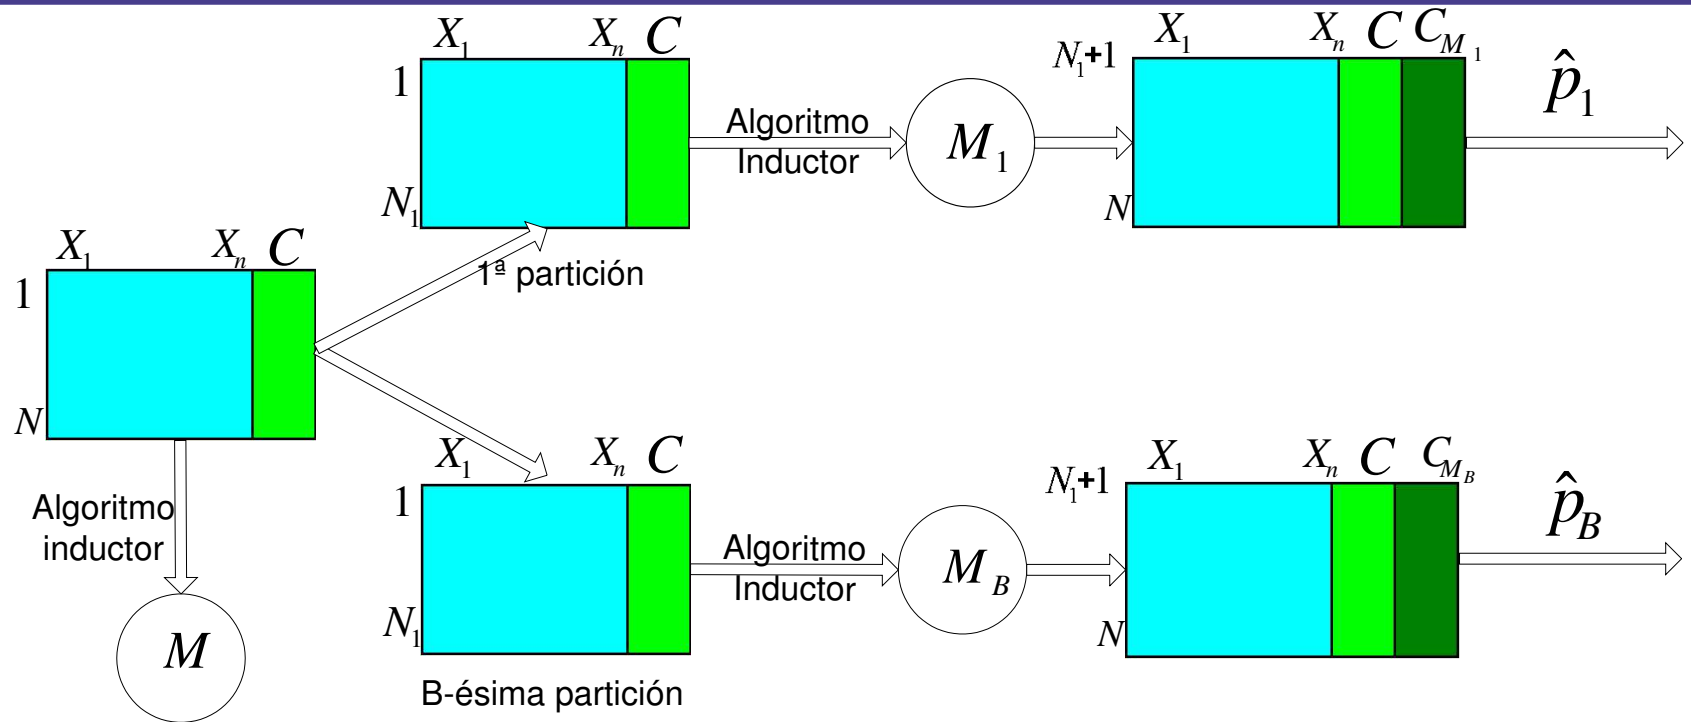
Estimación de la probabilidad de clasificación correcta



$$\hat{p}_M = \frac{1}{N - N_1} \sum_{i=1}^{N - N_1} \delta(c^{(N_1+i)} = c_M^{(N_1+i)})$$

Método H de estimación basado en entrenamiento y testeo

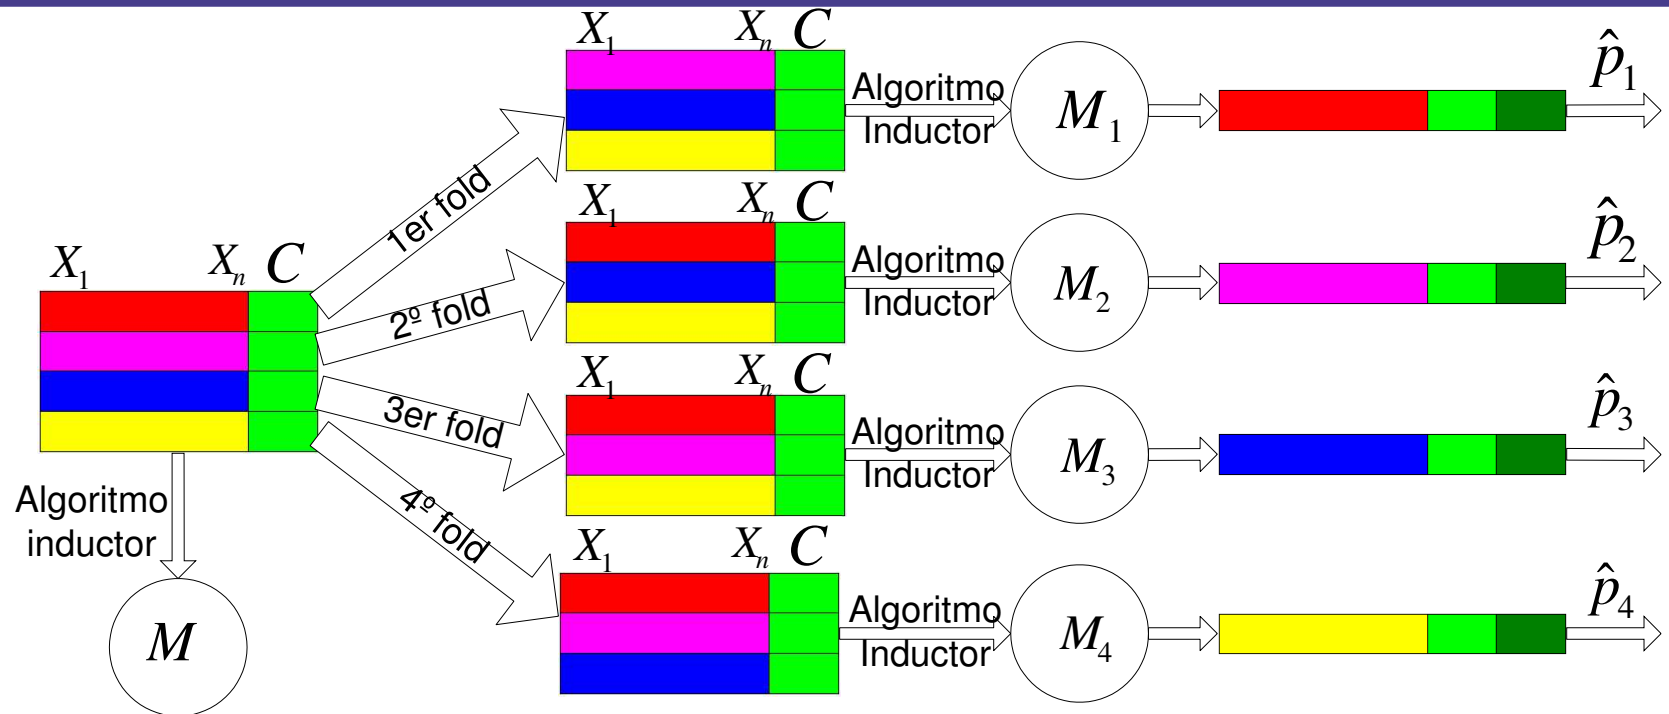
Estimación de la probabilidad de clasificación correcta



$$\hat{p}_M = \frac{1}{B} \sum_{i=1}^B \hat{p}_i$$

Método de estimación H repetidas veces

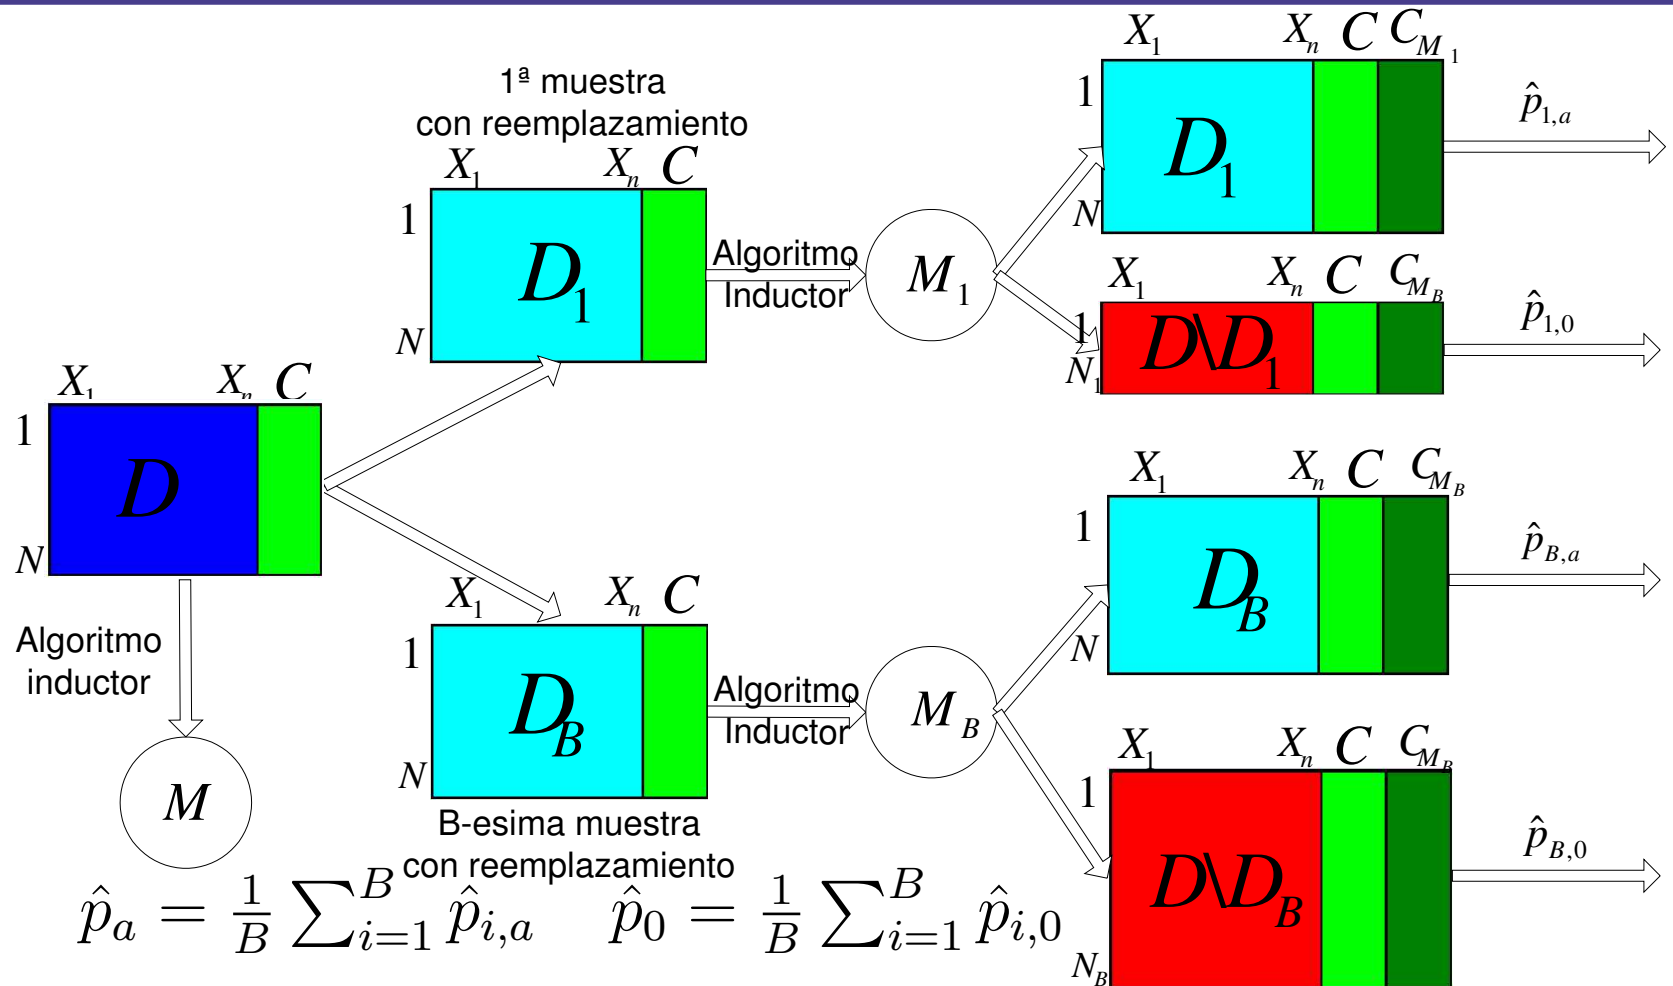
Estimación de la probabilidad de clasificación correcta



$$\hat{p}_M = \frac{1}{k} \sum_{i=1}^k \hat{p}_i$$

Método de estimación basado en k rodajas (k -fold cross validation). Si $k = N$ leave one out

Estimación de la probabilidad de clasificación correcta



$$\hat{p}_a = \frac{1}{B} \sum_{i=1}^B \hat{p}_{i,a} \quad \hat{p}_0 = \frac{1}{B} \sum_{i=1}^B \hat{p}_{i,0}$$

$$\hat{p}_M = \hat{p}_{0,632B_0} = (0,368\hat{p}_a + 0,632\hat{p}_0)$$

Método de estimación 0,632 bootstrapping

Estimación de la probabilidad de clasificación correcta

Sobre los distintos métodos:

- *Método H*: utilizarlo con N grande
- *Método H repetidas veces*: no hay control sobre los casos usados como entrenamiento (testeo)
- *Método de estimación basado en k rodajas (k -fold cross validation)*: estimación insesgada de la probabilidad de acierto, pero con alta varianza
- *Método de estimación 0,632 bootstraping*: insesgada en el límite y con baja varianza

Brier score

	X_1	\dots	X_n	C	$p(C_M = 0 \mathbf{x})$	$p(C_M = 1 \mathbf{x})$
$(\mathbf{x}^{(1)}, c^{(1)})$	$x_1^{(1)}$	\dots	$x_n^{(1)}$	1	0,18	0,82
$(\mathbf{x}^{(2)}, c^{(2)})$	$x_1^{(2)}$	\dots	$x_n^{(2)}$	0	0,51	0,49
\dots		\dots		\dots	\dots	
$(\mathbf{x}^{(N)}, c^{(N)})$	$x_1^{(N)}$	\dots	$x_n^{(N)}$	1	0,55	0,45

$$B = \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^2 [p(C_M = c|\mathbf{x}^{(i)}) - \delta(c^{(i)}, c_M^{(i)})]^2$$

$$B = \frac{1}{N} [(0,18 - 0)^2 + (0,82 - 1)^2 + (0,51 - 1)^2 + (0,49 - 0)^2 + \dots + (0,55 - 0)^2 + (0,45 - 1)^2]$$

Brier score

- Medida de la *calibración* para un clasificador que asigne, para cada patrón, probabilidades a posteriori a cada valor de la clase
- Suponiendo que la clase real del patrón x es 0, se trata de distinguir:

$$p(C_M = 0|x) = 0,51 \quad \text{y} \quad p(C_M = 1|x) = 0,97$$

- Interesa clasificadores con bajo valor de Brier (bastante seguros en sus predicciones)
- Para problemas con 2 clases: $0 \leq B \leq 2$

La curva ROC

Evaluación sensible al coste

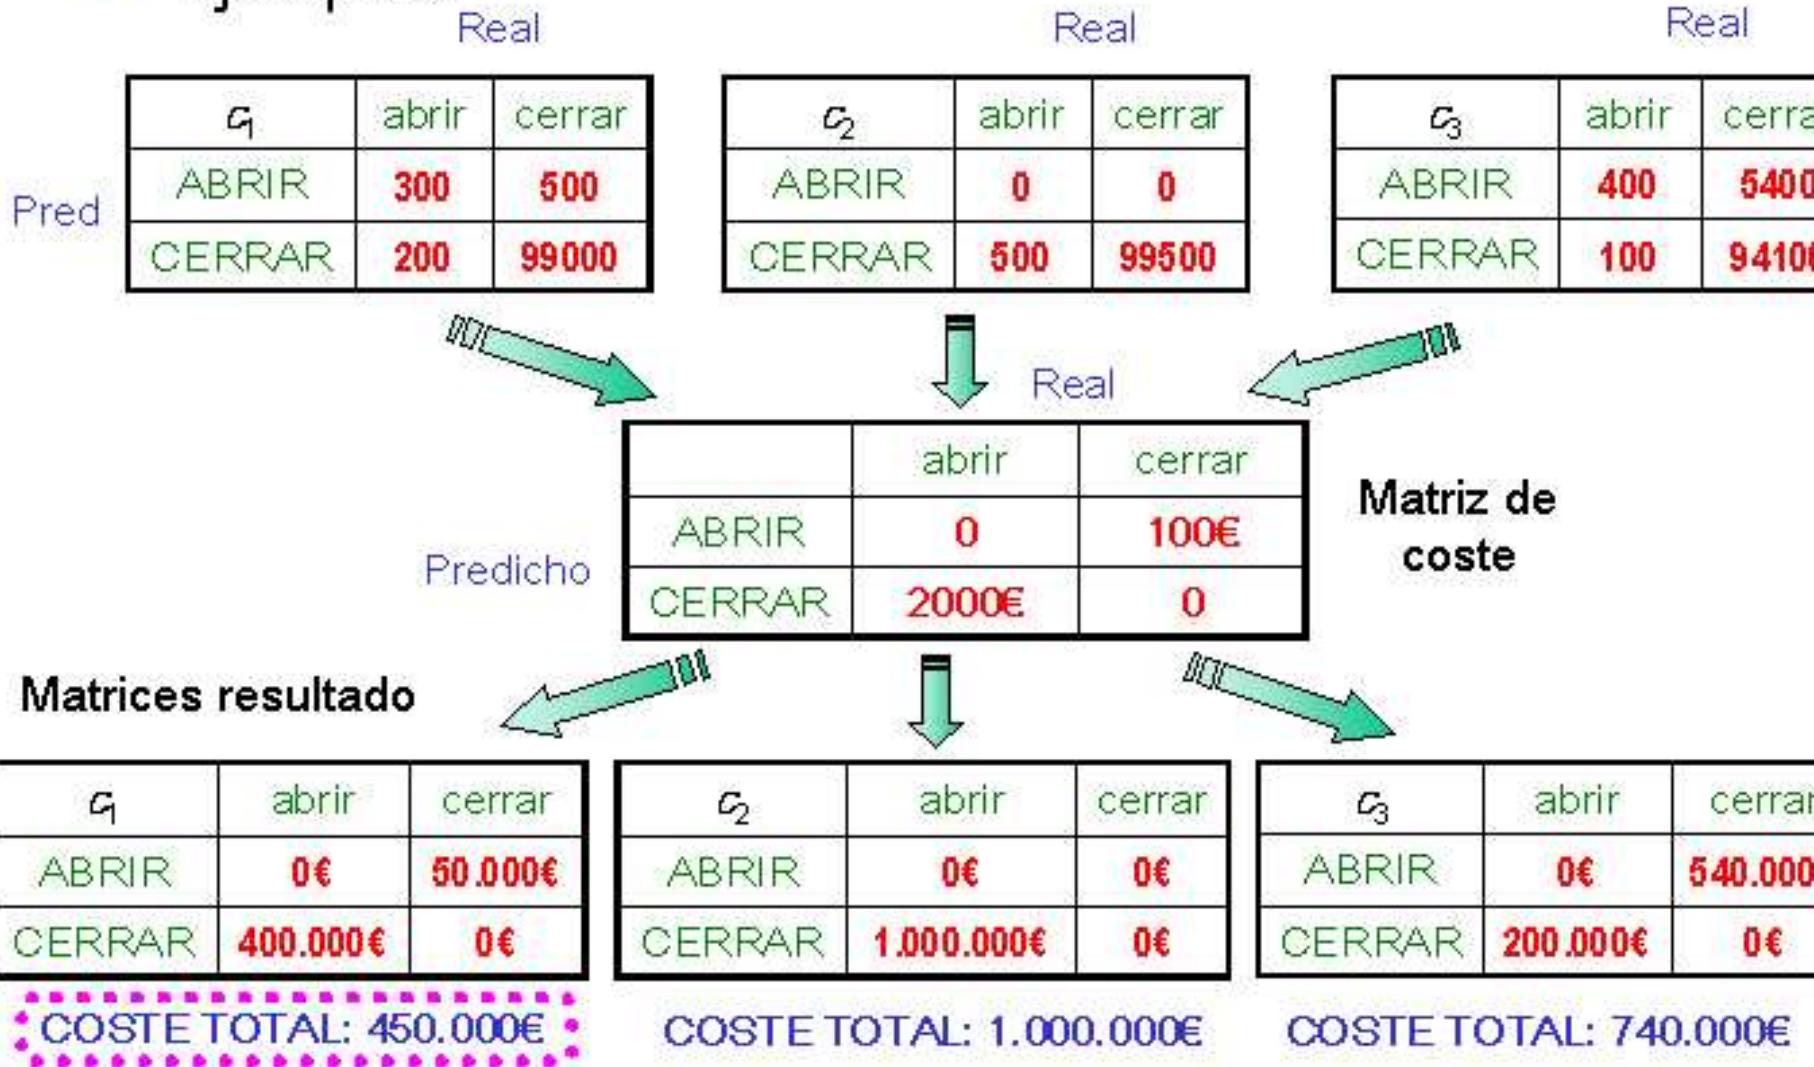
- En muchas situaciones los dos tipos de error que puede cometer un clasificador no tienen las mismas consecuencias
 - Dejar cerrada una válvula en una central nuclear, cuando es necesario abrirla, puede provocar una explosión, mientras que abrir una válvula cuando puede mantenerse cerrada, puede provocar una parada de la central
- Matriz de costes

		C Clase real	
		abrir	cerrar
		<hr/>	
	ABRIR	0	100 €
C_M Clase predicha			
	CERRAR	2000 €	0
		<hr/>	

- Lo importante no es obtener un clasificador que falle lo menos posible, sino uno que tenga coste menor

La curva ROC

- Ejemplos:



La curva ROC

- En muchas situaciones es difícil estimar la matriz de costes
- Análisis *ROC* (*Receiver Operating Characteristic*)
 - Usado por vez primera para evaluar radares en la segunda guerra mundial
 - Posteriormente se usó para el análisis de respuesta de transistores
 - A partir de 1970 se usa para aplicaciones de diagnóstico médico
 - A finales de los 90 se comienza a usar en minería de datos

La curva ROC

- El espacio ROC
 - Se normaliza la matriz de confusión por columnas:
TPR, FNR TNR, FPR.

		Real	
		abrir	cerrar
Pred	ABRIR	400	12000
	CERRAR	100	87500


$$\begin{aligned} \text{TPR} &= 400 / 500 = 80\% \\ \text{FNR} &= 100 / 500 = 20\% \\ \text{TNR} &= 87500 / 99500 = 87,9\% \\ \text{FPR} &= 12000 / 99500 = 12,1\% \end{aligned}$$

True Positives



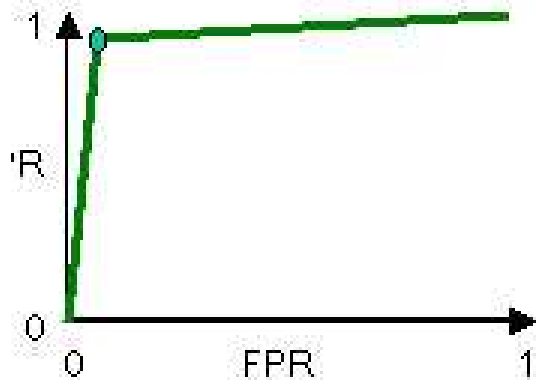
		Real	
		abrir	cerrar
Pred	ABRIR	0,8	0,121
	CERRAR	0,2	0,879

Espacio ROC

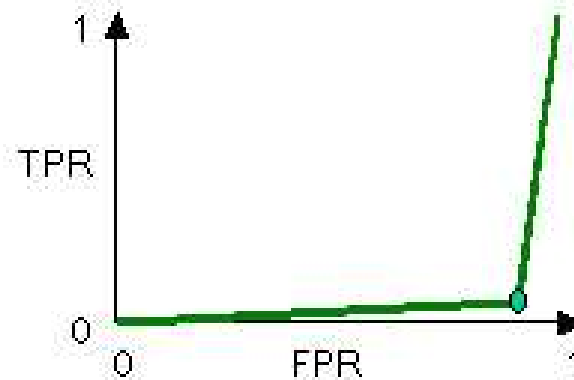


La curva ROC


- Espacio ROC: buenos y malos clasificadores.



- **Buen clasificador.**
 - Alto TPR.
 - Bajo FPR.




- **Mal clasificador.**
 - Bajo TPR.
 - Alto FPR.



- **Mal clasificador (en realidad).**

La curva ROC

- *Convex hull* (casco convexo) a partir de la poligonal uniendo varios puntos (FPR, TPR)
- Dichos puntos pueden provenir de varios clasificadores o de un mismo clasificador (variando el umbral)



La curva ROC

Seleccionando el mejor clasificador

- Si cada punto de la curva ROC representa un clasificador: escoger el que tenga mayor valor de: $\frac{FP_{cost}}{FN_{cost}} \cdot \frac{Neg}{Pos}$
- Si cada punto de la curva ROC corresponde a un umbral con el que se toma la decisión: seleccionar el clasificador con mayor área bajo la curva (AUC)

