



OPENCOURSEWARE

APRENDIZAJE AUTOMÁTICO PARA EL ANÁLISIS DE DATOS

GRADO EN ESTADÍSTICA Y EMPRESA

Ricardo Aler

# CLASIFICACIÓN CON MUESTRAS DESBALANCEADAS

# ORGANIZACIÓN

- **Evaluación** con muestras desbalanceadas
  - Matriz de confusión
  - La métrica AUC: el área bajo la curva ROC
- **Aprendizaje** con muestras desbalanceadas

# Usar particiones estratificadas

- Tanto en train/test (holdout) como en validación cruzada.
- Para que el test sea mas representativo
- La distribución de clases que existe en el conjunto de datos disponibles, se intenta mantener en los conjuntos de train y test (o en cada uno de los folds de validación cruzada)
  - Ejemplo: si en el conjunto original un 99% de los datos pertenecen a la clase negativa y 1% a la positiva, la estratificación intentará que esa proporción se mantenga en train y test

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

- Ya sabemos que usar el error de clasificación (o  $\text{accuracy} = 1 - \text{error}$ ) es engañoso para muestras desbalanceadas.
- Ejemplo:
  - Tenemos varios clasificadores  $c_1, c_2, c_3$  que predicen si se ha de abrir o cerrar la válvula del módulo de refrigeración de una central nuclear.
  - Para evaluar los clasificadores usamos un conjunto de datos obtenido en el último mes, donde un operario ha decidido en cada momento si se había de abrir o cerrar la fórmula.
    - 100.000 ejemplos, de los cuales 99.500 son de la clase “Cerrar” y 500 son de la clase “Abrir”.
  - Supongamos que el clasificador  $c_2$  obtiene una tasa de aciertos (accuracy) del 99.5%, que es muy alta, pero es lo que puede obtener un clasificador trivial (clase mayoritaria)
  - Además, tenemos un 100% de fallos en la clase “Cerrar” (que en este caso es la más importante).

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

- En el ejemplo anterior vemos que un único número (accuracy) no es suficiente para darnos una información correcta, cuando tenemos distribuciones desbalanceadas
- Matriz de confusión/contingencia (p.ej. para el conjunto de test):

Real

Predicho

|            |           |            |
|------------|-----------|------------|
|            | abrir (p) | cerrar (n) |
| ABRIR (P)  | TP        | FP         |
| CERRAR (N) | FN        | TN         |

Diagonal de los aciertos

Real

Pred

|        |       |        |
|--------|-------|--------|
| $c_1$  | abrir | cerrar |
| ABRIR  | 300   | 500    |
| CERRAR | 200   | 99000  |

Hay un total de 100000 datos, 500 positivos y 99500 negativos

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

- En el ejemplo anterior vemos que un único número (accuracy) no es suficiente para darnos una información correcta, cuando tenemos distribuciones desbalanceadas
- Matriz de confusión/contingencia (p.ej. para el conjunto de test):

Real

|                       | abrir (p) | cerrar (n) |
|-----------------------|-----------|------------|
| Predicho<br>ABRIR (P) | TP        | FP         |
| CERRAR (N)            | FN        | TN         |

Diagonal de los errores

Real

| $c_1$         | abrir | cerrar |
|---------------|-------|--------|
| Pred<br>ABRIR | 300   | 500    |
| CERRAR        | 200   | 99000  |

Hay un total de 100000 datos, 500 positivos y 99500 negativos

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

- Normalmente, a la matriz de confusión se la normaliza por columnas

Real

|          |                                       |                                       |
|----------|---------------------------------------|---------------------------------------|
|          | abrir (p)<br>t <sub>pos</sub> =TP+FN  | cerrar (n)<br>t <sub>neg</sub> =FP+TN |
| Predicho | ABRIR (P)<br>TPR=TP/t <sub>pos</sub>  | CERRAR (N)<br>FPR=FP/t <sub>neg</sub> |
|          | CERRAR (N)<br>FNR=FN/t <sub>pos</sub> | ABRIR (P)<br>TNR=TN/t <sub>neg</sub>  |

Normalizada por columnas

Sin normalizar

Normalizada

Real

|      |                |       |        |
|------|----------------|-------|--------|
|      | c <sub>1</sub> | abrir | cerrar |
| Pred | ABRIR          | 300   | 500    |
|      | CERRAR         | 200   | 99000  |

Real

|      |                |       |        |
|------|----------------|-------|--------|
|      | c <sub>1</sub> | abrir | cerrar |
| Pred | ABRIR          | 0.60  | 0,005  |
|      | CERRAR         | 0.40  | 0.995  |

$$t_{pos} = 300 + 200 = 500$$

$$t_{neg} = 500 + 99000 = 99500$$

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

- Ejemplo: (conjunto de test de 100.000 instancias)

Real

| $c_1$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 300   | 500    |
| CERRAR | 200   | 99000  |

$$t_{pos} = 300 + 200 = 500, \quad t_{neg} = 500 + 99000 = 99500$$

Pred

$$ACC: 0.993 = (300 + 99000) / 100000$$

$$TPR = 300 / 500 = 0.60$$

$$FNR = 200 / 500 = 0.40$$

$$TNR = 99000 / 99500 = 0.995$$

$$FPR = 500 / 99500 = 0.005$$

$$BAC = \text{macromedia} = (0.60 + 0.995) / 2 = 0.80$$

Real

| $c_1$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 0.60  | 0,005  |
| CERRAR | 0.40  | 0.995  |

Pred

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

pos = 300+200 = 500, neg = 500+99000 = 99500

- Ejemplo: (conjunto de test de 100.000 instancias)

Real

| $c_1$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 300   | 500    |
| CERRAR | 200   | 99000  |

Pred

ACC:  $0.993 = (300+99000)/100000$

TPR=  $300 / 500 = 0.60$

FNR=  $200 / 500 = 0.40$

TNR=  $99000 / 99500 = 0.995$

FPR=  $500 / 99500 = 0.005$

BAC = macromedia =  $(0.60 + 0.995) / 2 = 0.80$

Real

| $c_2$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 0     | 0      |
| CERRAR | 500   | 99500  |

ACC:  $0.995 = (0+99500)/100000$

TPR=  $0 / 500 = 0.0$

FNR=  $500 / 500 = 1.0$

TNR=  $99500 / 99500 = 1.0$

FPR=  $0 / 99500 = 0.0$

BAC = Macromedia=  $(0 + 1) / 2 = 0.5$

Real

| $c_1$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 0.60  | 0,005  |
| CERRAR | 0.40  | 0.995  |

Pred

Real

| $c_2$  | abrir | cerrar |
|--------|-------|--------|
| ABRIR  | 0.0   | 0.0    |
| CERRAR | 1.0   | 1.0    |

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

pos = 300+200 = 500, neg = 500+99000 = 99500

- Ejemplo: (conjunto de test de 100.000 instancias)

Real

|        | $c_1$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 300   | 500    |
| CERRAR |       | 200   | 99000  |

ACC:  $0.993 = (300+99000)/100000$

TPR=  $300 / 500 = 0.60$

FNR=  $200 / 500 = 0.40$

TNR=  $99000 / 99500 = 0.995$

FPR=  $500 / 99500 = 0.005$

BAC = macromedia =  $(0.60 + 0.995) / 2 = 0.80$   
= balanced accuracy

Real

|        | $c_2$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 0     | 0      |
| CERRAR |       | 500   | 99500  |

ACC:  $0.995 = (0+99500)/100000$

TPR=  $0 / 500 = 0.0$

FNR=  $500 / 500 = 1.0$

TNR=  $99500 / 99500 = 1.0$

FPR=  $0 / 99500 = 0.0$

BAC = Macromedia=  $(0 + 1) / 2 = 0.5$

Real

|        | $c_3$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 400   | 5400   |
| CERRAR |       | 100   | 94100  |

ACC:  $0.945 = (400+94100)/100000$

TPR=  $400 / 500 = 0.80$

FNR=  $100 / 500 = 0.20$

TNR=  $94100 / 99500 = 0.946$

FPR=  $5400 / 99500 = 0.054$

Macromedia=  $(0.80 + 0.946) / 2 = 0.873$

Real

|        | $c_1$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 0.60  | 0,005  |
| CERRAR |       | 0.40  | 0.995  |

Real

|        | $c_2$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 0.0   | 0.0    |
| CERRAR |       | 1.0   | 1.0    |

Real

|        | $c_3$ | abrir | cerrar |
|--------|-------|-------|--------|
| Pred   |       |       |        |
| ABRIR  |       | 0.80  | 0.054  |
| CERRAR |       | 0.20  | 0.946  |

# EVALUACIÓN CON MUESTRAS DESBALANCEADAS

pos = 300+200 = 500, neg = 500+99000 = 99500

- Ejemplo: (conjunto de test de 100.000 instancias)

|      | Real   |       |        | Real   |       |        | Real   |       |        |
|------|--------|-------|--------|--------|-------|--------|--------|-------|--------|
|      | $c_1$  | abrir | cerrar | $c_2$  | abrir | cerrar | $c_3$  | abrir | cerrar |
| Pred | ABRIR  | 300   | 500    | ABRIR  | 0     | 0      | ABRIR  | 400   | 5400   |
|      | CERRAR | 200   | 99000  | CERRAR | 500   | 99500  | CERRAR | 100   | 94100  |

|      | Real   |       |        | Real   |       |        | Real   |       |        |
|------|--------|-------|--------|--------|-------|--------|--------|-------|--------|
|      | $c_1$  | abrir | cerrar | $c_2$  | abrir | cerrar | $c_3$  | abrir | cerrar |
| Pred | ABRIR  | 0.60  | 0,005  | ABRIR  | 0.0   | 0.0    | ABRIR  | 0.80  | 0.054  |
|      | CERRAR | 0.40  | 0.995  | CERRAR | 1.0   | 1.0    | CERRAR | 0.20  | 0.946  |

ACC:  $0.993 = (300+99000)/100000$   
 BAC = macromedia =  $(0.60 + 0.995) / 2 = 0.80$

ACC:  $0.995 = (0+99500)/100000$   
 BAC = Macromedia =  $(0 + 1) / 2 = 0.5$

ACC:  $0.945 = (400+94100)/100000$   
 Macromedia =  $(0.80 + 0.946) / 2 = 0.873$

¿Qué clasificador es mejor?

# NOTA

- Medidas que combinan los aciertos en los positivos y en los negativos. Todas están entre cero y uno.
  - Balanced accuracy (BAC) o macro-media:  $(\text{TPR} + \text{TNR}) / 2$
  - Youden's J index:  $\text{TPR} + \text{TNR} - 1 = \text{BAC} * 2 - 1$ 
    - (equivalente a BAC)
  - F1-score:  $2 * \text{TP} / (2 * \text{TP} + \text{FN} + \text{FP})$

# EVALUACIÓN VS. APRENDIZAJE

- Evaluación vs. Aprendizaje
- Ya sabemos cómo evaluar un modelo con muestras desbalanceadas (matriz de confusión)
- Pero el modelo se sigue construyendo según las técnicas vistas hasta ahora: no hay garantía de que un método construya un modelo que optimice la Macromedia o el TPR.
- Vamos por tanto a tratar el caso de aprender buenos modelos cuando hay muestras desbalanceadas.

# APRENDIZAJE CON MUESTRAS DESBALANCEADAS

- Los algoritmos de aprendizaje típicos tienden a maximizar la tasa de aciertos (accuracy)
- En problemas de muestra desbalanceada eso suele equivaler a aprender bien la clase mayoritaria a costa de aprender mal la minoritaria
- Es decir, los métodos vistos hasta ahora, tienden a aprender modelos que resultan en matrices de confusión como las siguientes:

|        |       | Real  |        |
|--------|-------|-------|--------|
|        |       | abrir | cerrar |
| Pred   | $c_1$ | abrir | cerrar |
|        | ABRIR | 0.60  | 0,005  |
| CERRAR | 0.40  | 0.995 |        |

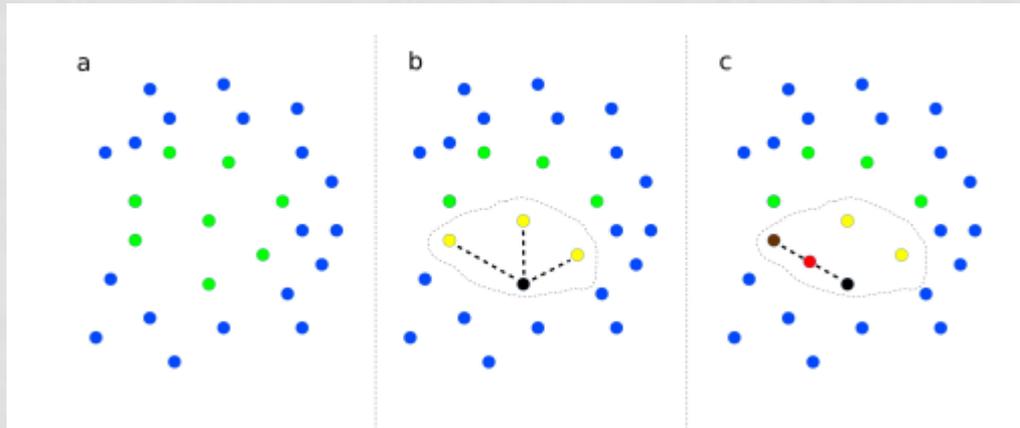
|        |       | Real  |        |
|--------|-------|-------|--------|
|        |       | abrir | cerrar |
|        | $c_2$ | abrir | cerrar |
|        | ABRIR | 0.0   | 0.0    |
| CERRAR | 1.0   | 1.0   |        |

# APRENDIZAJE CON MUESTRAS DESBALANCEADAS

- Solución 1: entrenar varios modelos (p. ej. con distintos algoritmos) y seleccionar aquel que aprenda razonablemente bien la clase minoritaria (o que maximice el BAC).
  - Es costoso en tiempo y el que aparezca un buen modelo es cuestión de casualidad
- Solución 2: remuestreo:
  - Submuestreo: eliminar datos de la clase mayoritaria para equilibrarla con la minoritaria
  - Sobremuestreo: replicar datos de la clase minoritaria. También se pueden utilizar pesos para las instancias, como se hacía en boosting
  - SMOTE: Synthetic Minority Over-sampling Technique
- Solución 3: thresholding (cambiar el threshold o punto de corte, del modelo)

# APRENDIZAJE CON MUESTRAS DESBALANCEADAS

- SMOTE: Synthetic Minority Over-sampling Technique:
  - Se generan instancias situadas entre instancias de la clase minoritaria
  - Hiper-parámetros:
    - ¿Cuántos vecinos?
    - ¿Cuántas muestras de la clase minoritaria hay que generar?



# APRENDIZAJE CON MUESTRAS DESBALANCEADAS

- La representación ROC de un clasificador discreto es un punto en el espacio ROC

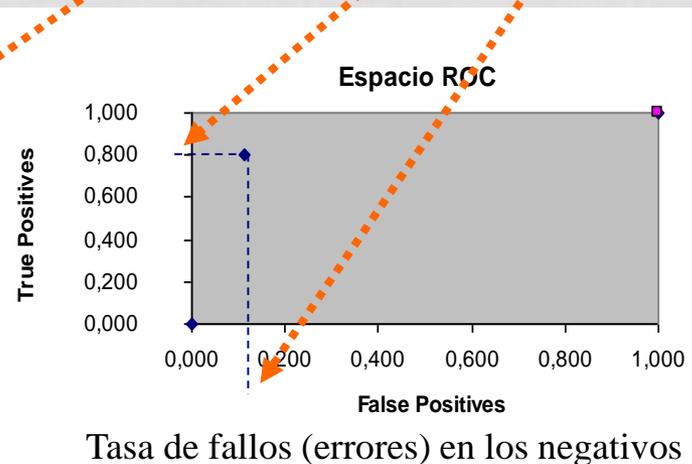
|      |        | Real  |        |
|------|--------|-------|--------|
|      |        | abrir | cerrar |
| Pred | ABRIR  | 400   | 12000  |
|      | CERRAR | 100   | 87500  |



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

$$\begin{aligned} \text{TPR} &= 400 / 500 = 0.80 \\ \text{FNR} &= 100 / 500 = 0.20 \\ \text{TNR} &= 87500 / 99500 = 0.879 \\ \text{FPR} &= 12000 / 99500 = 0.121 \end{aligned}$$

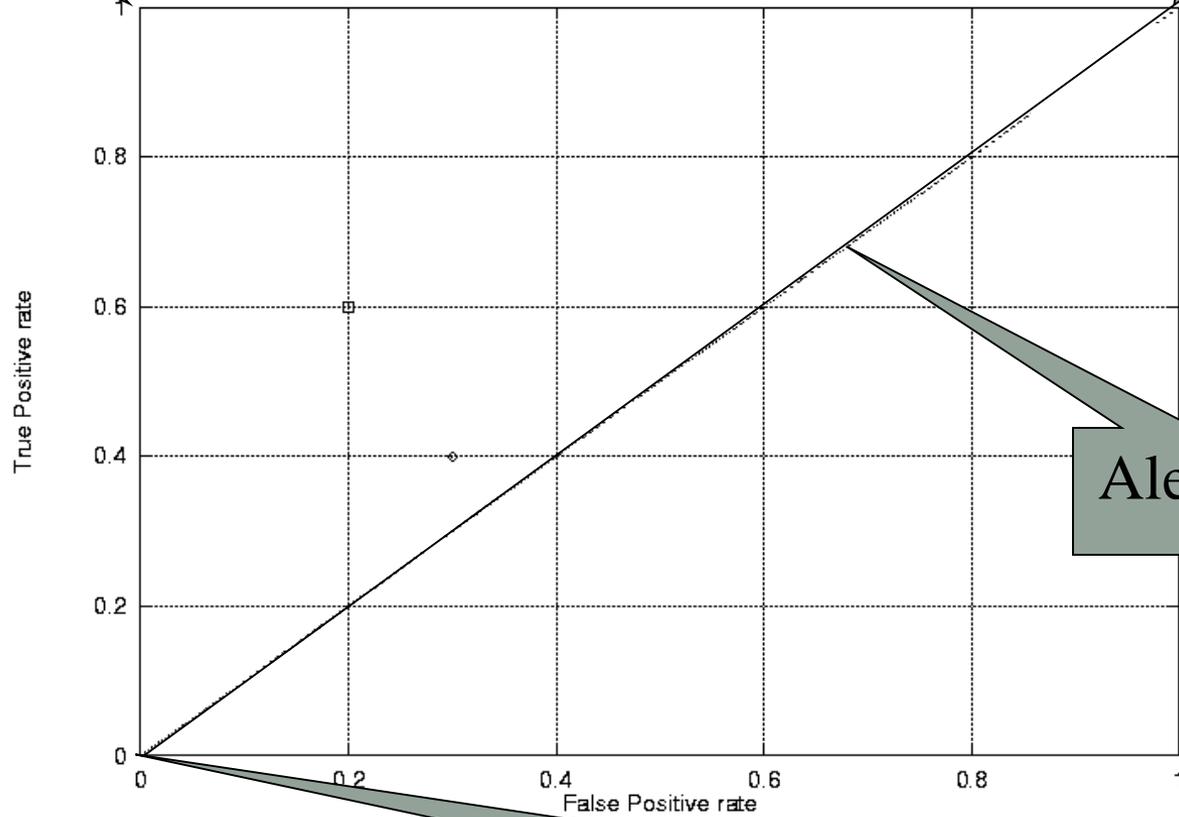
Tasa de aciertos en los positivos



# ESPACIO ROC

Ideal

Siempre positivo



Aleatorio

Siempre negativo

# ¿PORQUÉ LA DIAGONAL REPRESENTA UN CLASIFICADOR ALEATORIO?

- $TPR = FPR$
- Supongamos que un clasificador clasifica **aleatoriamente** los datos como:
  - positivo el 50% de las veces
  - negativo el 50% de las veces
  - Por pura casualidad, acertará con el 50% de los positivos y fallará con el 50% de los negativos
    - $TPR = \Pr(P | p) = 0.5$ ;  $FPR = \Pr(P | n) = 0.5$

# ¿PORQUÉ LA DIAGONAL REPRESENTA UN CLASIFICADOR ALEATORIO?

- TPR = FPR
- Supongamos que un clasificador clasifica **aleatoriamente** los datos como:
  - positivo el 90% de las veces
  - negativo el 10% de las veces
  - Por pura casualidad, acertará con el 90% de los positivos y fallará con el 90% de los negativos
    - $TPR = \Pr(P | p) = 0.9$ ;  $FPR = \Pr(P | n) = 1 - \Pr(N | n) = 0.9$

# CLASIFICADOR DISCRETO VS. SCORING CLASSIFIER (SC)

- Un clasificador discreto predice una clase entre las posibles.
- Un scoring classifier (sc) predice una clase, pero acompaña un valor de fiabilidad a cada predicción.
- Un ejemplo de sc es Random Forest, que puede estimar probabilidades
- Pero existen sc que no son capaces de devolver probabilidades, pero si valores (scores  $g(x)$ ) que indican la certidumbre de que un dato pertenezca a una clase
- Por ejemplo, un clasificador lineal, o una máquina de vectores de soporte, que devuelven una distancia del dato a la frontera:
  - Si el valor es muy negativo, cercano a la clase 0
  - Si el valor es muy positivo, cercano a la clase 1

# CLASIFICADOR DISCRETO VS. SCORING CLASSIFIER (SC)

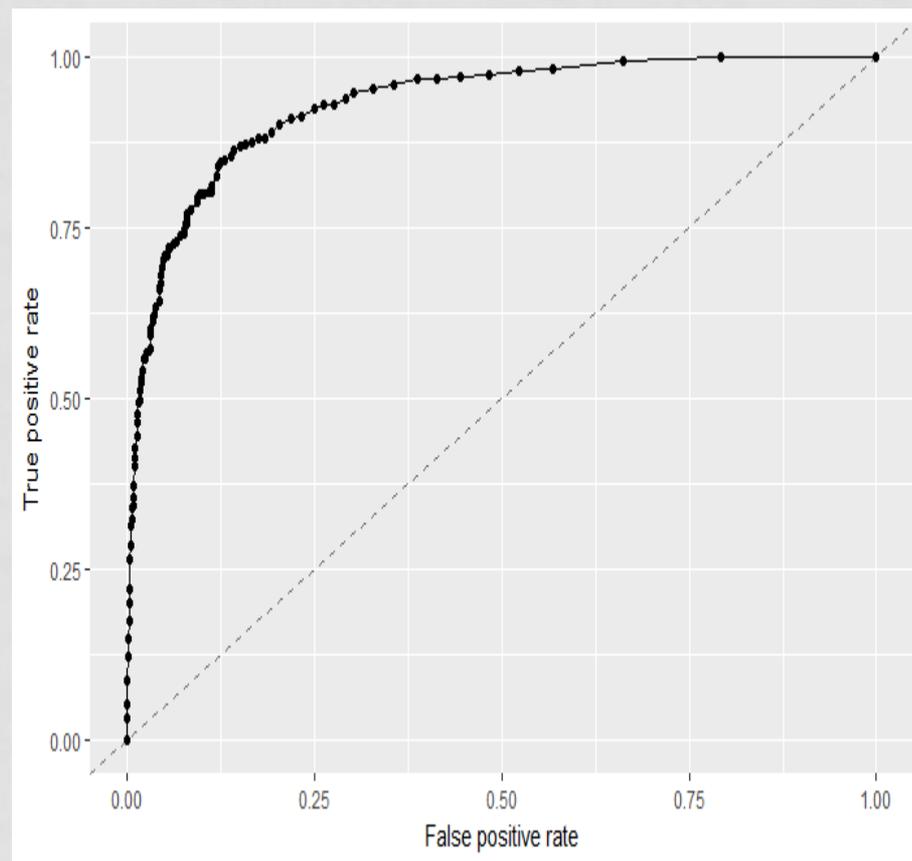
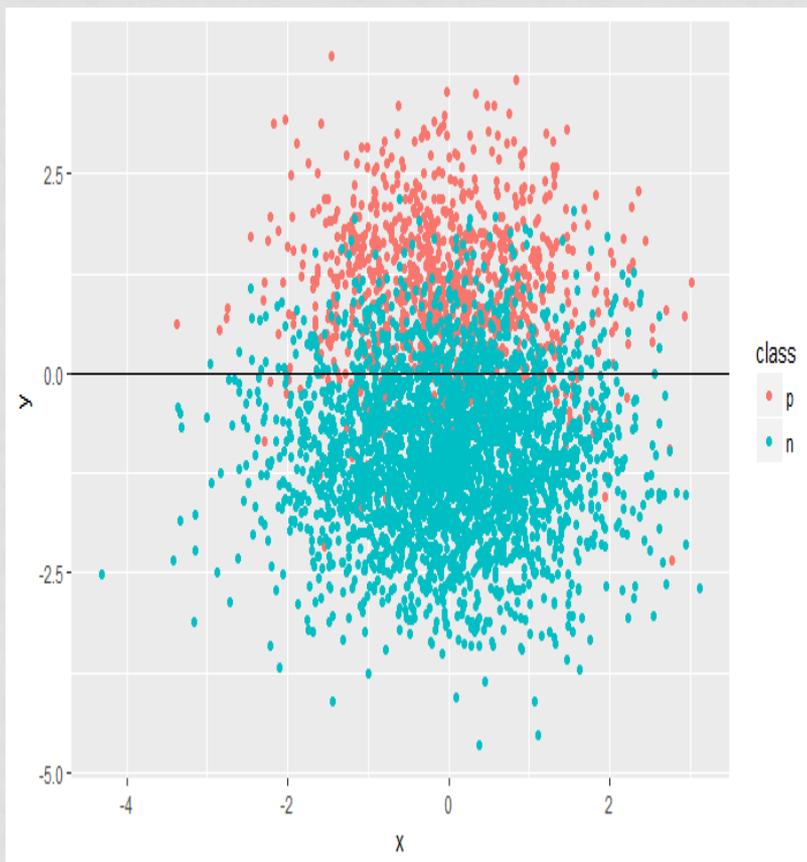
- Por ejemplo, un clasificador lineal, o una máquina de vectores de soporte, que devuelven una distancia del dato a la frontera:
  - Si el valor  $g(x)$  es muy negativo, cercano a la clase 0
  - Si el valor  $g(x)$  es muy positivo, cercano a la clase 1
- Los scores también pueden estar entre 0 y 1 (como con RF)
- Es fácil transformar un sc en un clasificador binario discreto, sin mas que fijar un threshold  $t$  (valor de corte):
  - Si  $g(x) \leq t$  entonces clase 0
  - Si  $g(x) > t$  entonces clase 1
- Eso quiere decir que para distintos  $t$ , tenemos distintos clasificadores discretos, es decir, distintos puntos en el espacio ROC

# EJEMPLO DE SC

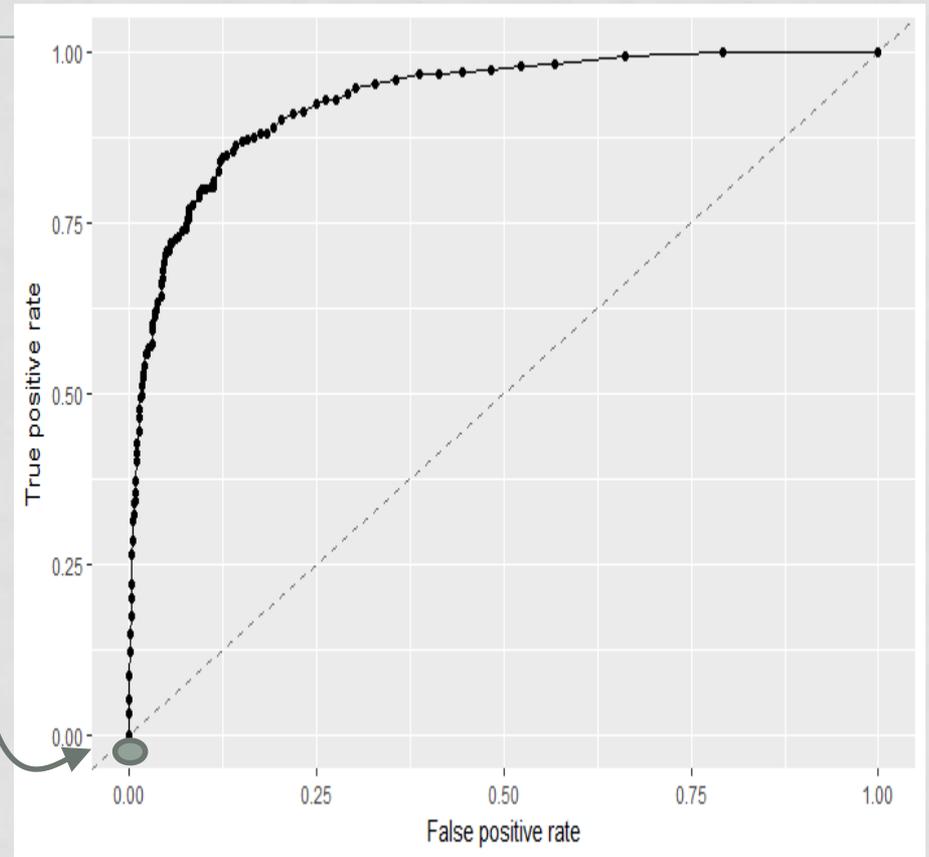
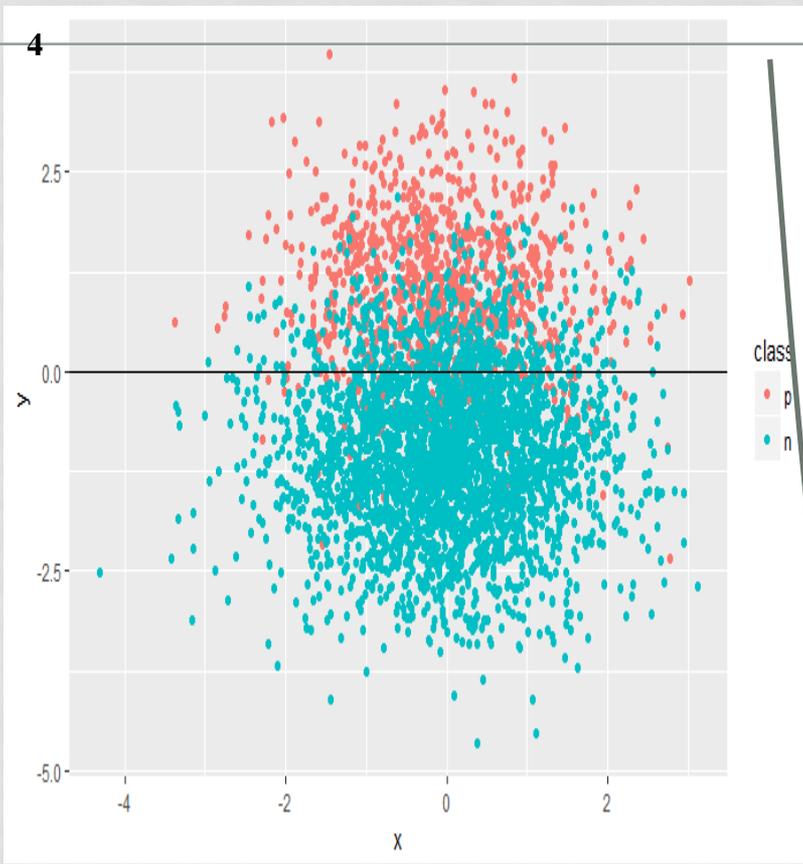
- Modelo lineal para este problema
- El “score” es la distancia a la frontera (valor positivo a un lado y negativo al otro)
- Clasificaremos un dato como positivo si la distancia (score) a la frontera  $\geq$  threshold
  - (en este caso, las distancias (scores) en la zona roja serán positivas y las de la zona azul, negativas)



- Para cada threshold, habrá un punto en la curva ROC

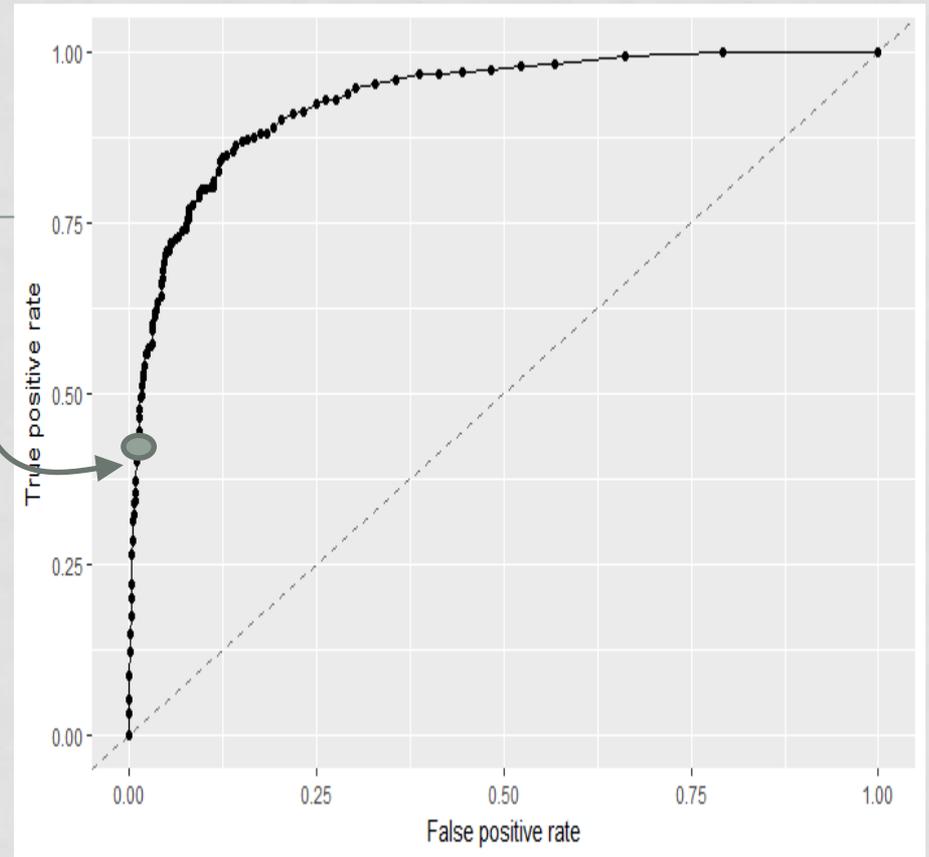
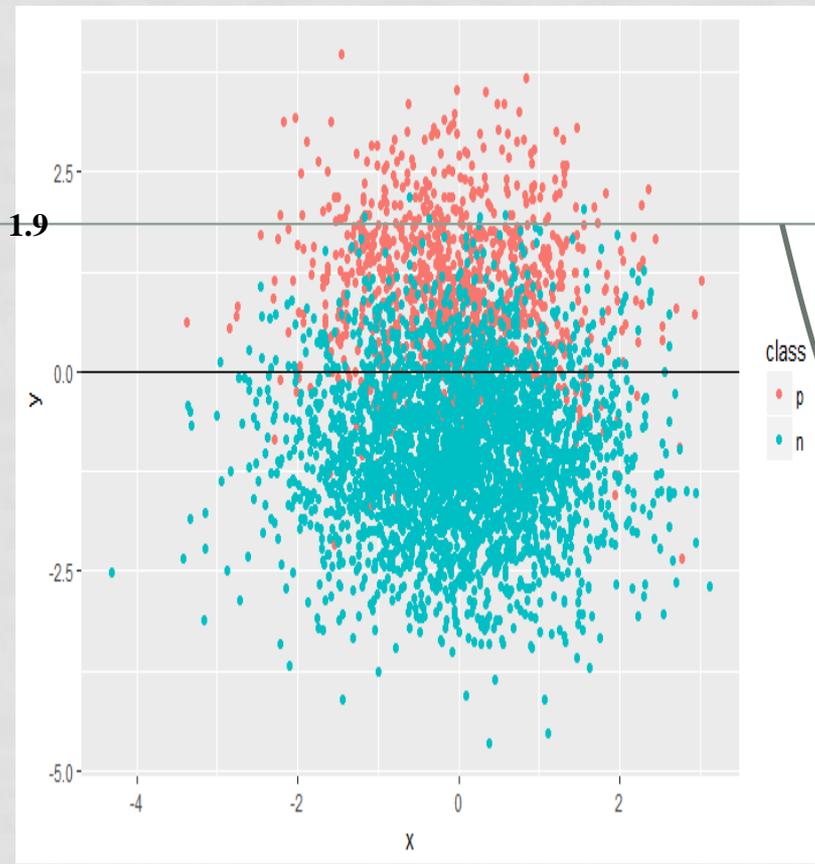


- Para cada threshold, habrá un punto en la curva ROC
- Si  $\text{score} \geq 4$  entonces “positivo”, en caso contrario “negativo”



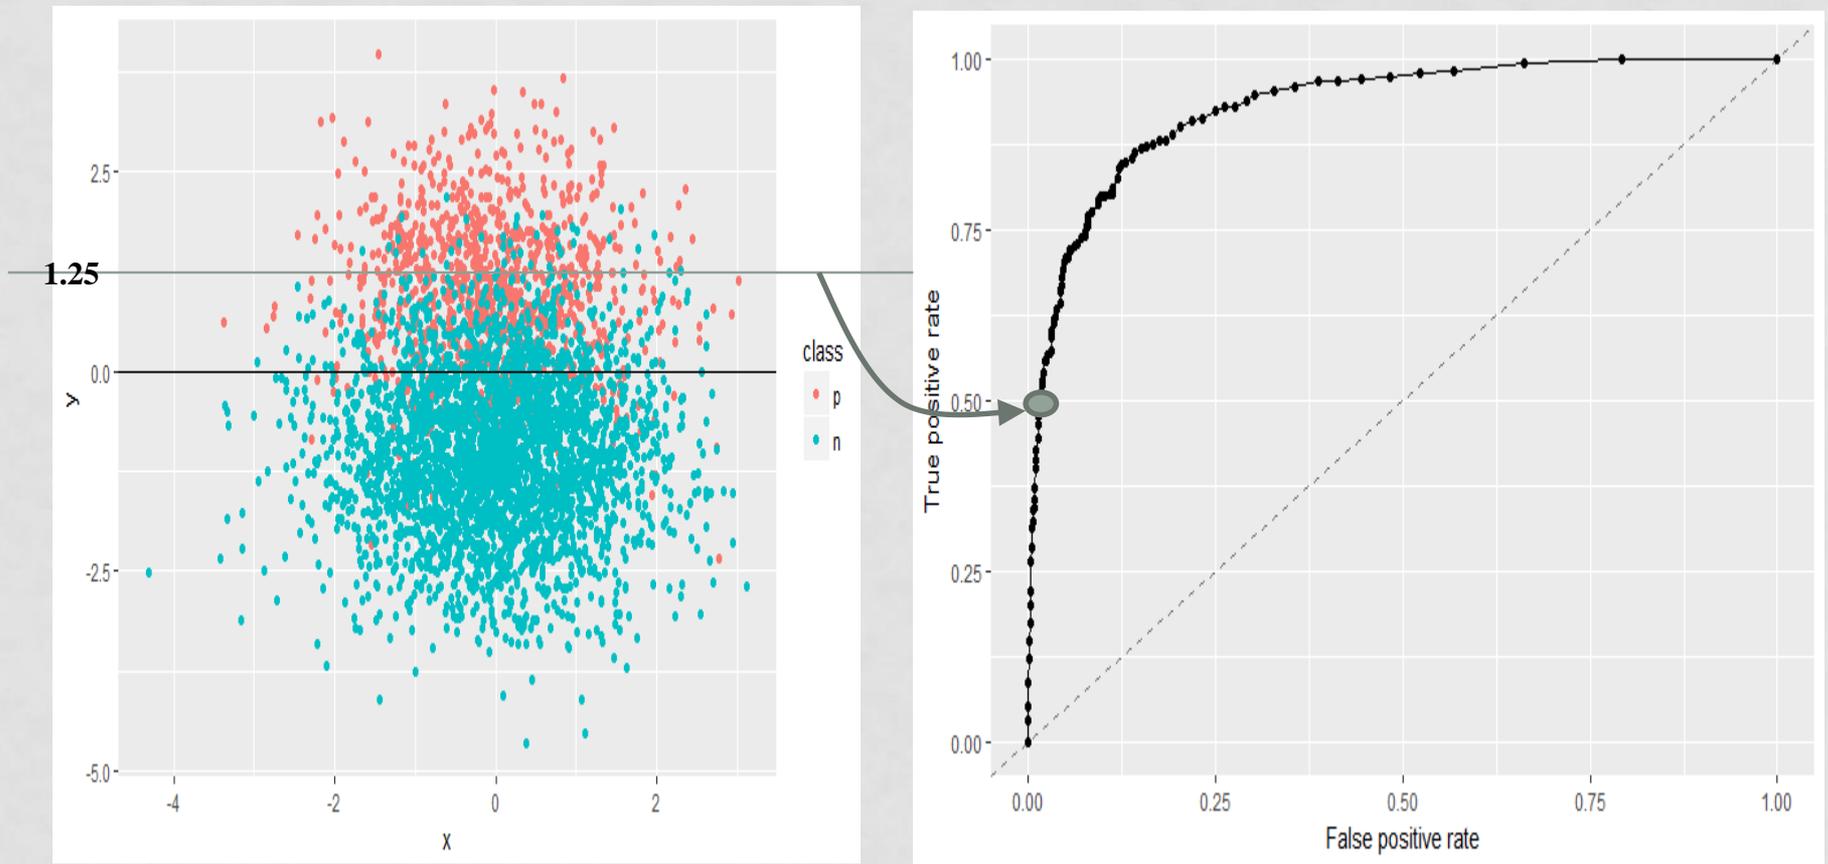
Todo lo clasifica como “n”:  $\text{TPR}=0$ ,  $\text{FPR}=0$

- Para cada threshold, habrá un punto en la curva ROC
- Si distancia  $\geq 1.9$  entonces “positivo”, en caso contrario “negativo”



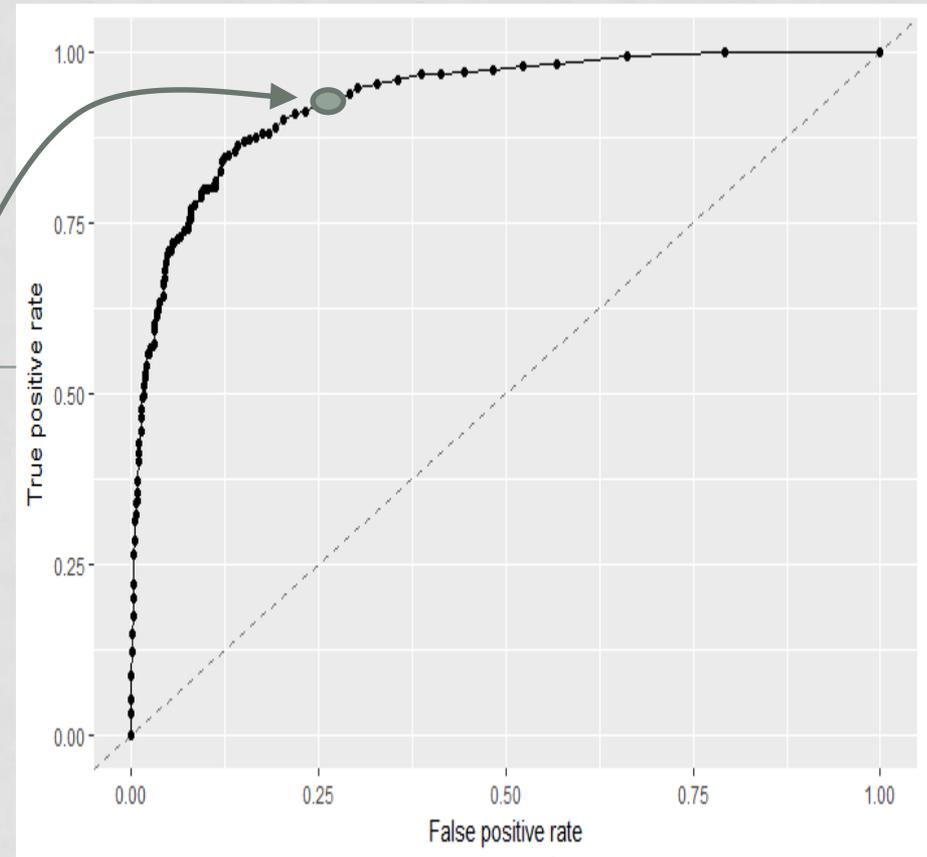
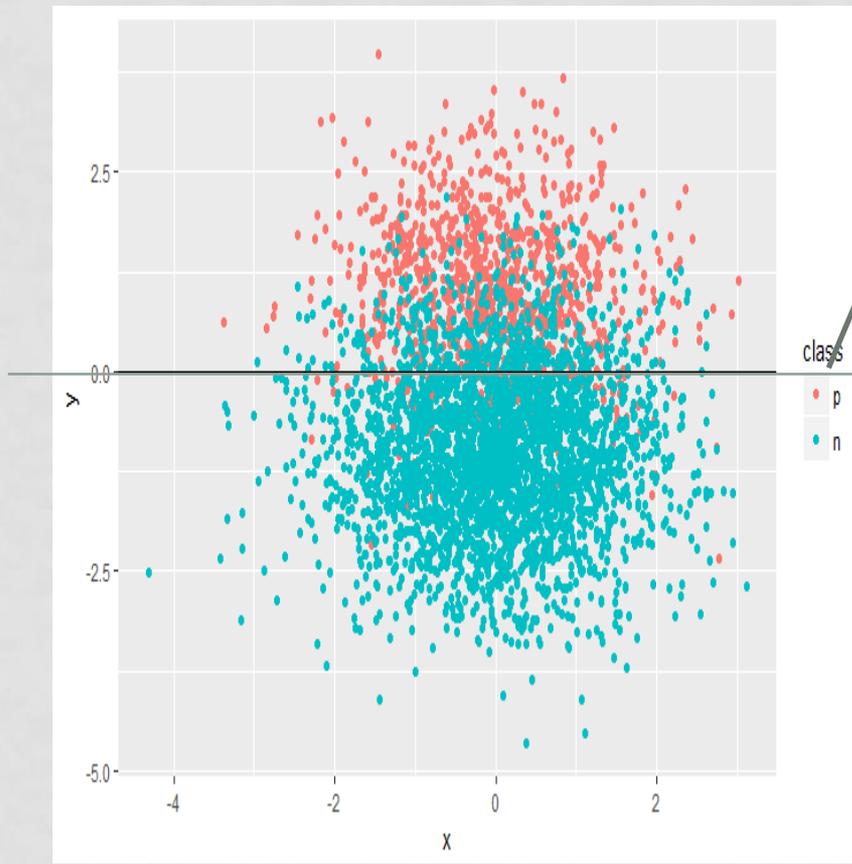
Clasifica los de encima como “p” y los de debajo como “n”.

- Para cada threshold, habrá un punto en la curva ROC
- Si distancia  $\geq 1.25$  entonces “positivo”, en caso contrario “negativo”



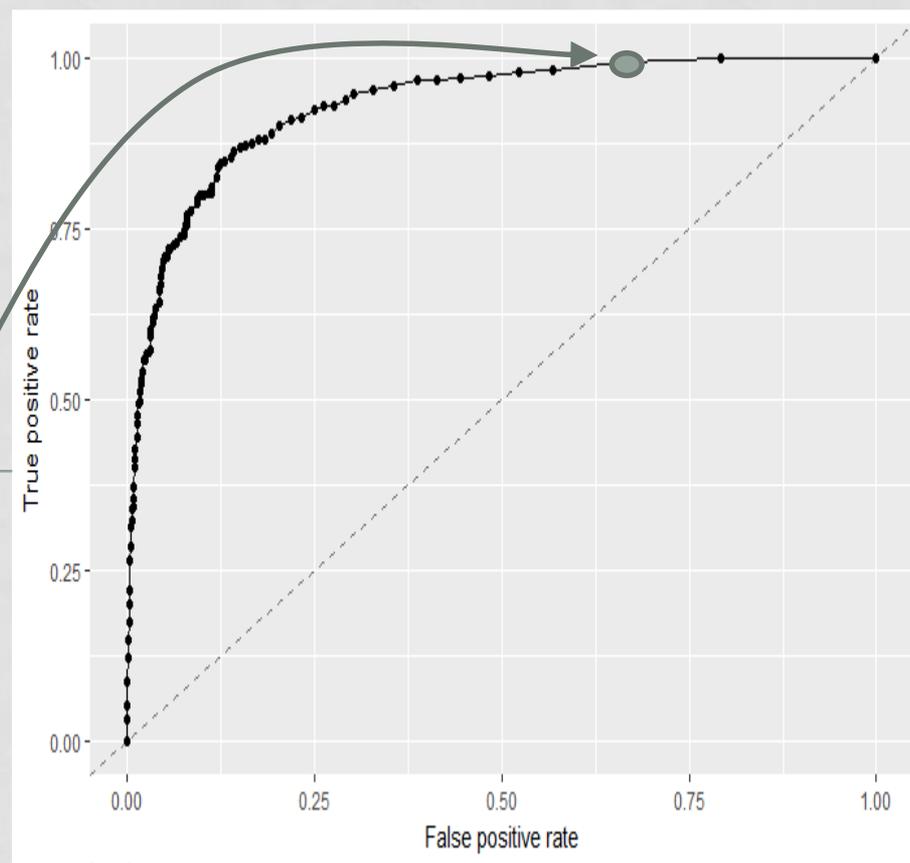
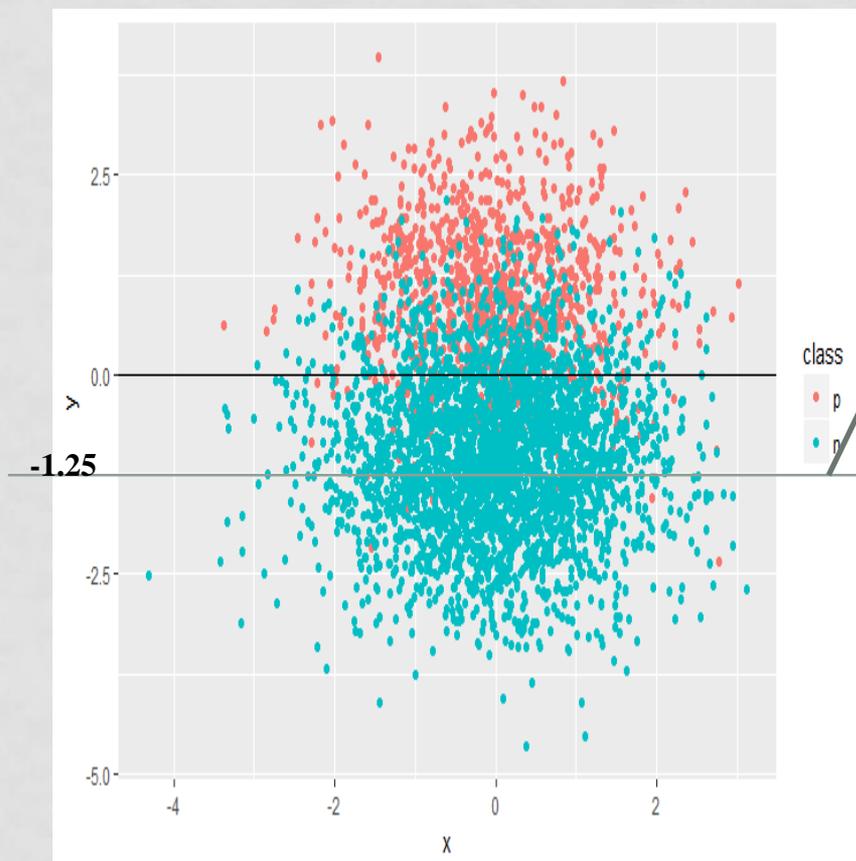
Clasifica la mitad de los positivos como “p” y la mayor parte de los negativos como “n”.

- Para cada threshold, habrá un punto en la curva ROC
- Si distancia  $\geq 0$  entonces “positivo”, en caso contrario “negativo”



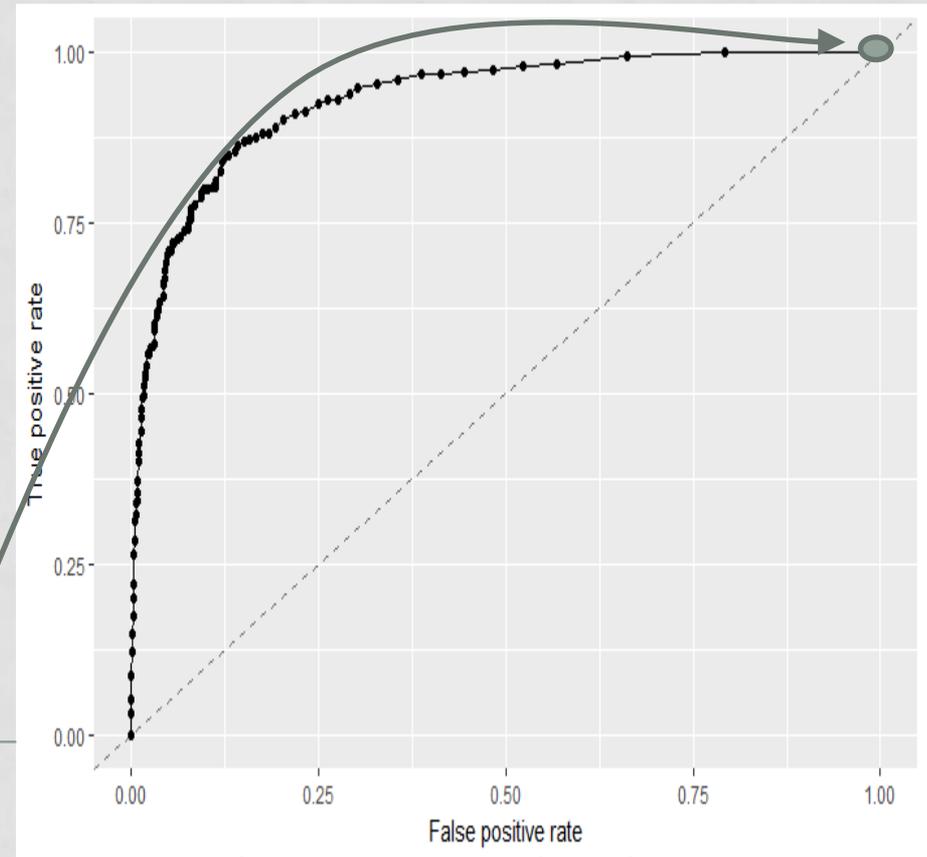
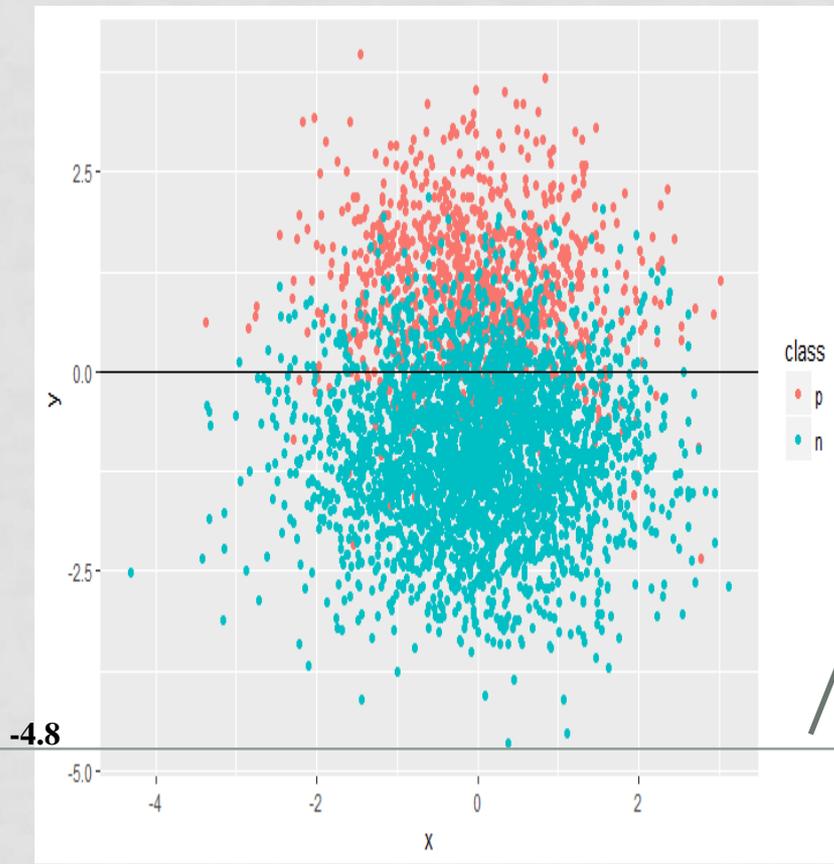
Clasifica casi todos los positivos como “p” pero se equivoca en unos cuantos negativos (25%).

- Para cada threshold, habrá un punto en la curva ROC
- Si distancia  $\geq -1.25$  entonces “positivo”, en caso contrario “negativo”



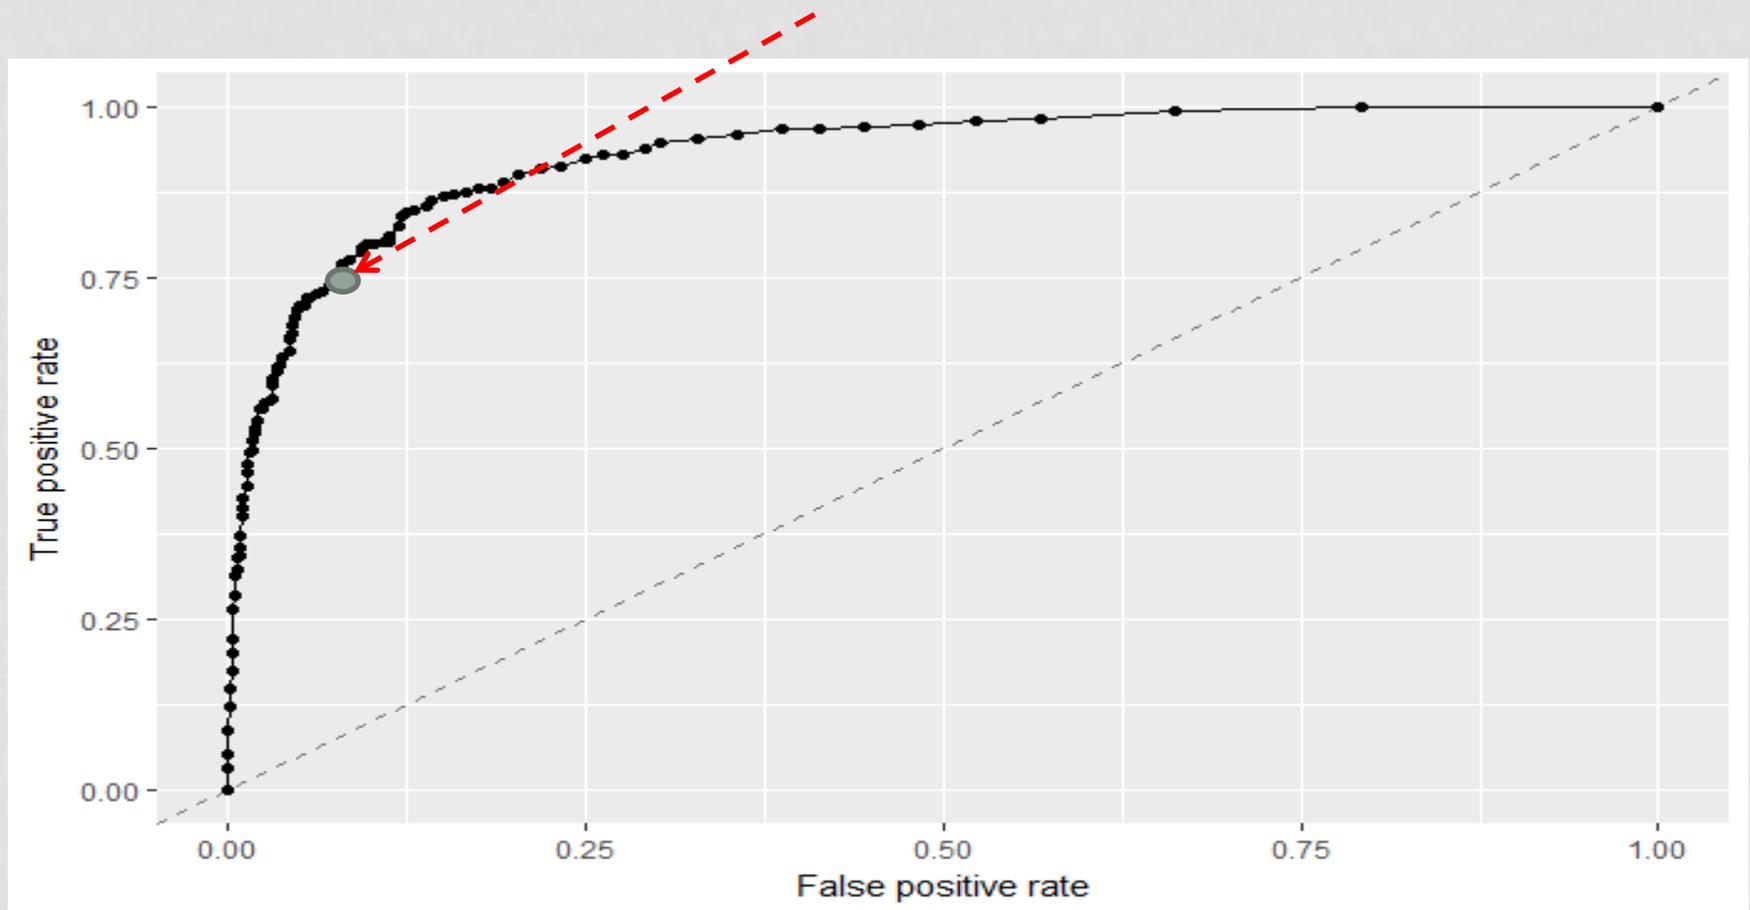
Clasifica prácticamente todos los positivos como “p” pero se equivoca ya en bastantes negativos (25%).

- Para cada threshold, habrá un punto en la curva ROC
- Si distancia  $\geq -4.8$  entonces “positivo”, en caso contrario “negativo”



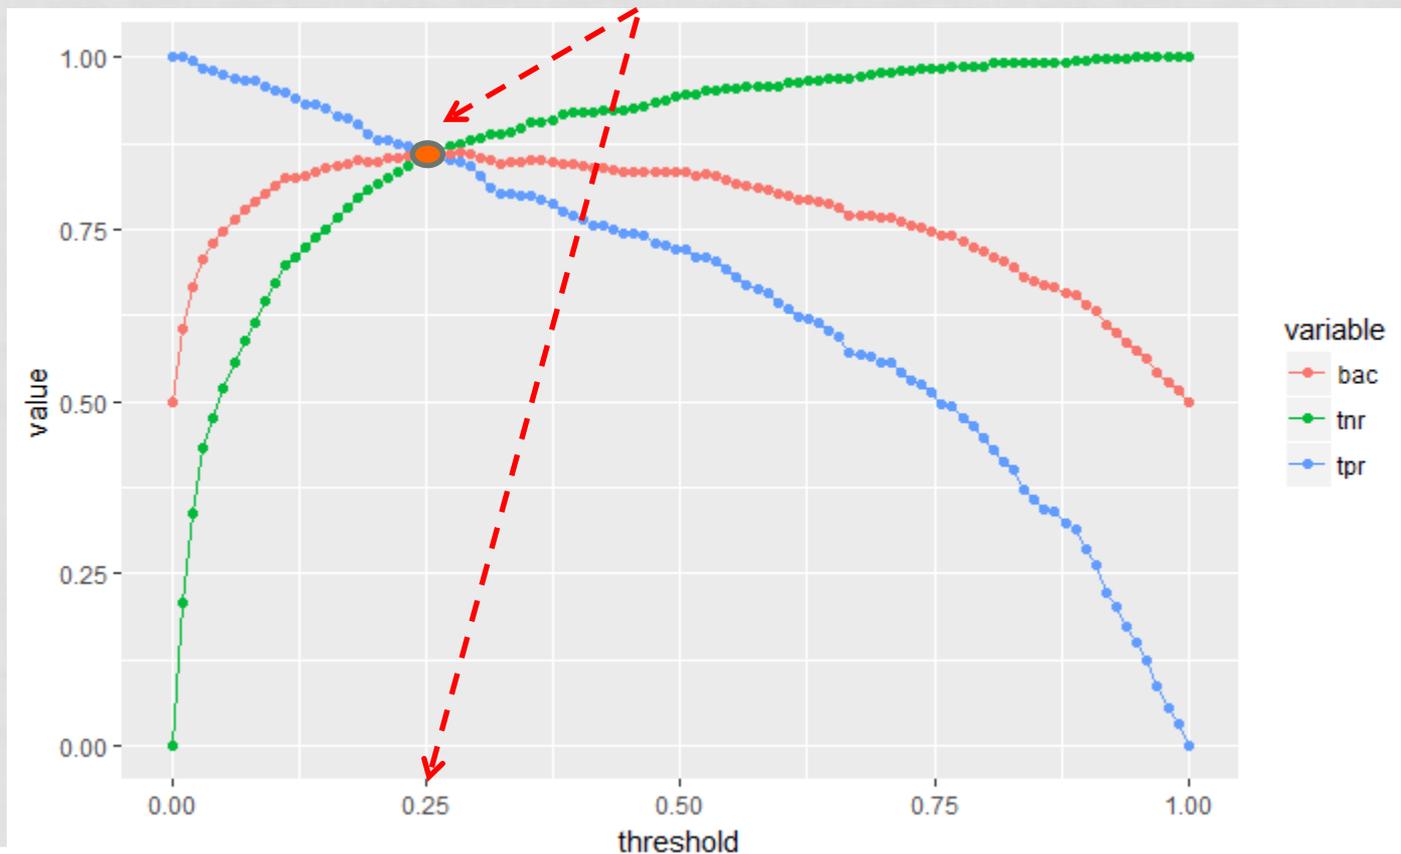
Clasifica todo como “p”, con lo que se equivoca en todos los negativos.

- Podemos usar la curva ROC para elegir un threshold adecuado.
- Por ejemplo, si es suficiente con acertar la clase positiva en un 75%:



# THRESHOLDING

- En general, podemos usar “thresholding”: ajustar el threshold para optimizar alguna medida. Por ejemplo, el “balanced accuracy” (macromedia)



# ORGANIZACIÓN

- **Evaluación** teniendo en cuenta distribución y coste
- **Aprendizaje** teniendo en cuenta distribución y coste
- **La Métrica AUC: el área bajo la curva ROC**

# MÉTRICA AUC

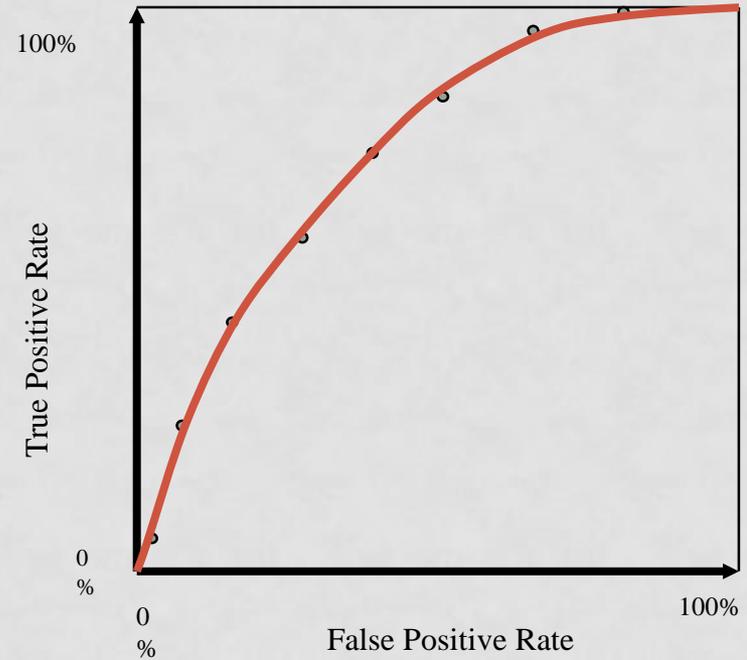
- Aparte de permitirnos elegir un *threshold* adecuado, las curvas ROC tienen otra utilidad en evaluación de modelos.
- Podemos usarlas para evaluar y comparar modelos.

# COMPARACIÓN DE CURVAS ROC

Buena



Mala



# LA MÉTRICA AUC

- Se puede demostrar que  $AUC = \text{probabilidad de que el score de una instancia positiva sea mayor que el de una instancia negativa} = P(X > Y)$
- Nótese que a diferencia del error, no se deja engañar por modelos que clasifican todos los datos como pertenecientes a la clase mayoritaria.
- Podemos ver esto con un clasificador discreto.

# AUC DE UN CLASIFICADOR DISCRETO

- La curva ROC de un clasificador discreto está constituida por tres puntos:
  - El punto ROC del clasificador
  - El del clasificador trivial que clasifica todo como negativo
  - El del clasificador trivial que clasifica todo como positivo
- Para clasificadores discretos  $AUC = (TN + TP)/2$  (la macromedia o BAC)
- Podemos ver que el AUC de un clasificador casi trivial será próxima a  $0.5 = (1+0)/2$

# EXTENSIÓN A MAS DE DOS CLASES

- La medida AUC se puede extender a más de dos clases.
  - Extensión de “todos los pares”

$$AUC_{HT} = \frac{1}{c(c-1)} \sum_{i=1}^c \sum_{j=1, j < i}^c AUC(i, j)$$

- Extensión “uno contra todos” (Fawcett)