



**Ricardo Aler Mur**

## **EVALUACIÓN DE TÉCNICAS DE APRENDIZAJE-2**

### **COMPARACIÓN DE MODELOS**

En esta clase se desarrolla de manera técnica una cuestión introducida en la clase anterior: la comparación de dos modelos.

- Además de estimar las prestaciones de un modelo, es interesante poder comparar de manera estadística las prestaciones de dos o más modelos. Se recalcará aquí, que aunque es importante que la prestación media de un modelo sea superior a la del otro, es también importante que la varianza no sea grande. De otra manera, no se podría afirmar rigurosamente que la diferencia en prestaciones no sea debida al azar.
- Se utiliza para ello el método descrito en el capítulo 5.5 del libro: *Data Mining: Practical Machine Learning Tools and Techniques, Second Edition* (Morgan Kaufmann Series in Data Management Systems)
- Se utiliza una validación cruzada repetida múltiples veces y corregida para evitar infravalorar la varianza.
- Se explica la idea de comparación estadística de hipótesis, p-value e intervalo de confianza.



## Comparación de dos modelos

- Sean  $x_1, \dots, x_{10}$  los resultados de 10-fold crossvalidation del algoritmo A
- Sean  $y_1, \dots, y_{10}$  los resultados de 10-fold crossvalidation del algoritmo B

$$x_i = \frac{1}{10} \sum_{j=1}^{10} x_{ij} \quad y_i = \frac{1}{10} \sum_{j=1}^{10} y_{ij}$$

- Es importante que las particiones usadas para A sean las mismas que las de B: siempre entrenamos y hacemos el test con el mismo fold. Disminuye la variabilidad y podemos hacer un test “pareado”

# Comparación de dos modelos

- Según el teorema central del límite, la suma de muchas variables aleatorias sigue una distribución Normal (Gaussiana). Por tanto las dos siguientes medias siguen una Normal:

$$\bar{x}_T = \frac{1}{10} \sum_{i=1}^{10} x_i = \frac{1}{10} \sum_{i=1}^{10} \frac{1}{10} \sum_{j=1}^{10} x_{ij} \quad \bar{y}_T = \frac{1}{10} \sum_{i=1}^{10} y_i = \frac{1}{10} \sum_{i=1}^{10} \frac{1}{10} \sum_{j=1}^{10} y_{ij}$$

- Si conociéramos la varianza de dichas Normales podríamos comprobar si las distribuciones solapan mucho (o si los intervalos de confianza solapan mucho)

# Comparación de dos modelos

- Desgraciadamente, aunque sabemos que  $\bar{x}_T$   $\bar{y}_T$  siguen distribuciones normales, no conocemos la varianza, pero podemos estimarla así:

$$\sqrt{\sigma_x^2 / k}$$

- Donde  $\sigma_x^2$  es la varianza de las  $k=10*10=100$  muestras  $x_{ij}$
- Tiene sentido que la varianza de la distribución disminuya a medida que aumentan las muestras (cuantas mas muestras, más precisa es la media)

# Comparación de dos modelos

- Como hemos tenido que estimar la varianza, ya no siguen una normal, sino una t-student (parecida a la normal), con  $10 \cdot 10 - 1$  grados de libertad  $\bar{x}_T$   $\bar{y}_T$ 
  - Usar un estimador para la varianza hace que haya más incertidumbre
- En lugar de usar  $x$  e  $y$ , usemos directamente la diferencia. Recordemos que los folds están pareados

$$d_{ij} = x_{ij} - y_{ij} \quad \bar{d}_T = \frac{1}{10} \sum_{i=1}^{10} \frac{1}{10} \sum_{j=1}^{10} d_{ij}$$

## *Comparación de dos modelos*

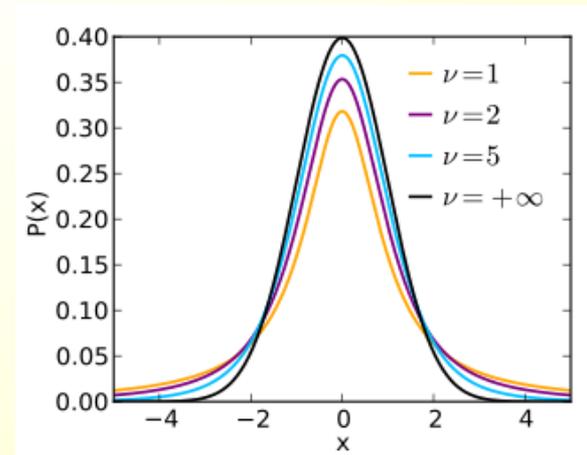
- Podemos decir que el siguiente estadístico  $t$  se distribuye según una  $t$ -student con  $10 \cdot 10 - 1$  grados de libertad:

$$t = \frac{\bar{d}}{\sqrt{\sigma_d^2 / k}}$$

# Comparación de dos modelos

- Para nuestros experimentos,  $d$  (y  $t$ ) tendrá un valor concreto.
- Test de contraste de hipótesis: si suponemos que el  $d$  real es cero, ¿cuál es la probabilidad de que  $d$  tenga el valor que tiene? Si es baja, entonces lo más probable es que no sea cero

$$t = \frac{\bar{d}}{\sqrt{\sigma_d^2/k}}$$



# Comparación de dos modelos

- Hasta ahora hemos supuesto que cada una de las 10 validaciones cruzadas se hace con un conjunto distinto (10 conjuntos independientes).
- Pero en la práctica, no se dispone de tantos datos y se reutiliza el mismo conjunto las 10 veces. Simplemente se desordena.
- Pero esto tiene el problema de que las 10 validaciones cruzadas ya no son independientes
- Estamos subestimando la varianza real. Por tanto muchas veces concluiremos que dos algoritmos son distintos cuando realmente no es así.
- En concreto, como el estimador de la varianza es inversamente proporcional a  $k$ , basta con hacer  $k$  enorme para que la varianza sea tan pequeña como queramos

$$\sqrt{\sigma_x^2 / k}$$

# Comparación de dos modelos

- Usaremos otro estimador corregido

$$k = 100, n_2/n_1 = 0.1/0.9,$$

$$t = \frac{\bar{d}}{\sqrt{\sigma_d^2/k}} \quad \rightarrow \quad t = \frac{\bar{d}}{\sqrt{\left(\frac{1}{k} + \frac{n_2}{n_1}\right)\sigma_d^2}}$$

# *Pasos para hacer el contraste de hipótesis entre el algoritmo A y B*

- Dos algoritmos A y B
- $\{x_{ij}, y_{ij} \mid i=1:r, j=1:k\}$  son el error de la i-esima validación cruzada en el fold j-esimo
- Las diferencias son:  $d_{ij} = x_{ij} - y_{ij}$ 
  - Analogía: repetir r veces secuencias de k tiradas de una moneda (trucada o no) y contar las  $d_{ij}$  caras
- La media es:  $\bar{d} = \frac{1}{r} \sum_{i=1}^{10} \frac{1}{k} \sum_{j=1}^{10} d_{ij}$
- Dos hipótesis:
  - H0: hipótesis nula.  $A=B$  o  $\bar{d} = 0$
  - H1:  $A \neq B$  o  $\bar{d} \neq 0$

# Pasos para hacer el contraste de hipótesis entre el algoritmo A y B

$$t = \frac{\bar{d}}{\sqrt{\sigma_d^2/k}}$$

- Si  $H_0$  fuera cierta, los distintos valores  $t$  para distintos conjuntos de datos disponibles  $T$ , se distribuirían según una t-student de media 0 con  $k-1$  grados de libertad (en este caso  $k = r * k$ )
- Sabida la distribución, si efectuamos el experimento de extraer una muestra de datos y calcular  $r$  validaciones cruzadas de  $k$  folds, podemos calcular la probabilidad de que el resultado esté entre  $-t$  y  $+t$  ( $t$  es el estadístico que ha sido calculado con los datos que teníamos).
- Es decir,  $p = \text{prob}(-t \leq x \leq +t)$ .  $P\text{value} = 1 - p$
- Si resulta que  $p$  es muy alta o que el  $p\text{value}$  es muy bajo, es que la probabilidad de observar  $t$  supuesta la hipótesis nula es muy baja, y por tanto hay que rechazar la hipótesis nula.
- Normalmente se considera que si  $p\text{value} \leq 0.05$ , se rechaza  $H_0$

# *Pasos para hacer el contraste de hipótesis entre el algoritmo A y B*

- En R,  $\text{probabilidad}(x < t) = \text{pt}(t, \text{df})$
- Si  $t > 0$ , entonces  $\text{prob}(x > t) = 1 - \text{pt}(t, \text{df})$  y como la t-student es simétrica,  $\text{prob}(-t < x) = 1 - \text{pt}(t, \text{df})$
- Por tanto, supuesta  $H_0$ , la probab
  - la probabilidad de que la observación sea mayor que  $|t|$  o menor que  $-|t|$  es:  
 $\text{pvalue} = 2(1 - \text{pt}(t, \text{df}))$
  - La probabilidad de que la observación esté en el intervalo alrededor de 0, entre  $-|t|$  y  $+|t|$  es:  
 $1 - \text{pvalue} = 1 - 2(1 - \text{pt}(t, \text{df}))$

# *Pasos para hacer el contraste de hipótesis entre el algoritmo A y B*

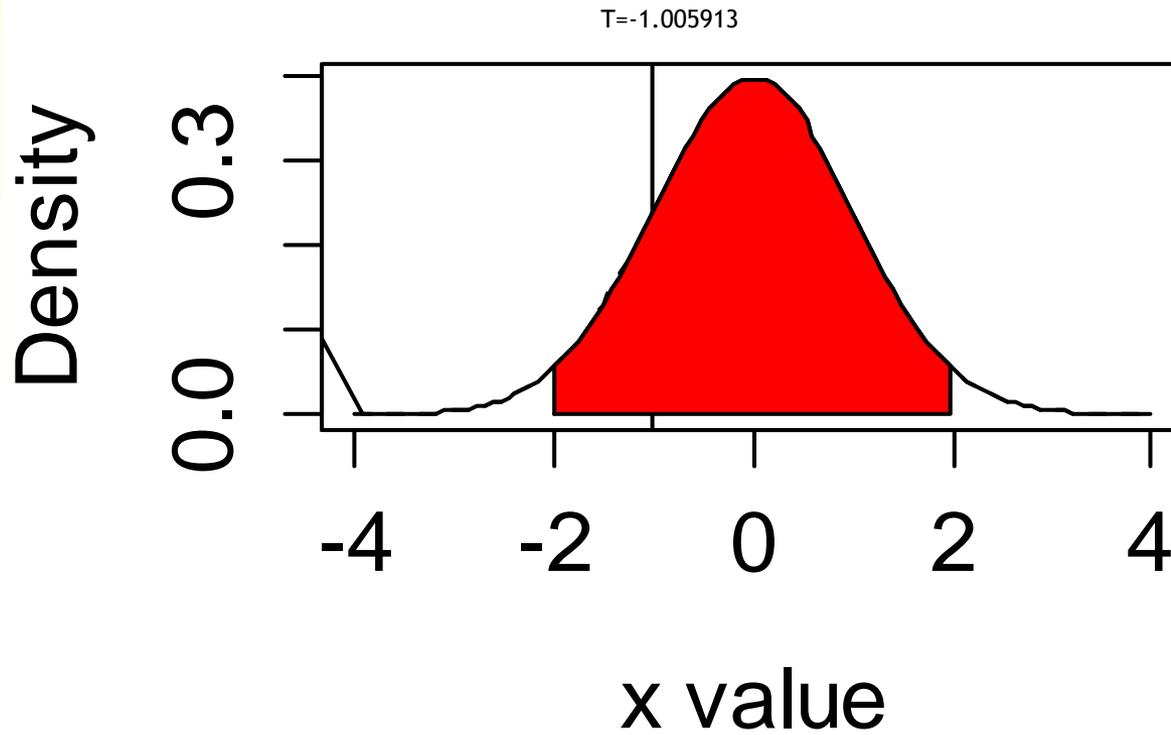
- Ejemplo de comparación de C4.5 y knn en el dominio Iris con  $r=k=10$
- KNN: error =  $0.0470093 \pm 0.02757903$
- C4.5: error =  $0.06272868 \pm 0.02322911$
- $t = -1.250795$

## KNN VS. C4.5

- $t = -1.250795$
- $pvalue = 2 * (1 - pt(abs(t), df = k * r - 1)) = 0.3169098$
- El intervalo que contiene el 95% de la probabilidad alrededor de 0 (es decir, deja fuera al  $2.5\% + 2.5\% = 5\%$  de la probabilidad) es:
  - [ $qt(0.05/2, df)$ ,  $qt(1 - 0.05/2, df)$ ]
  - [-1.984217 , 1.984217]
- Como  $t$  está dentro del intervalo, no podemos rechazar la hipótesis nula

# KNN VS. C4.5

## t Distribution



# *Pasos para hacer el contraste de hipótesis entre el algoritmo A y B*

- Ejemplo de comparación de C4.5 y knn en el dominio Iris con  $r=k=10$
- KNN: error =  $0.04315691 \pm 0.01321075$
- ZeroR: error =  $0.7831381 \pm 0.01964745$
- $t = -24.06936$
- Intervalo 95%:  $[-1.984217, 1.984217]$

## *KNN VS. ZeroR*

- $t = -24.06936$
- $pvalue = 2 * (1 - pt(abs(t), df = k * r - 1)) = 0$
- El intervalo que contiene el 95% es:  
[ $qt(0.05/2, df)$ ,  $qt(1 - 0.05/2, df)$ ]  
[-1.984217 , 1.984217]
- Como  $t$  está muy fuera del intervalo, rechazamos la hipótesis nula

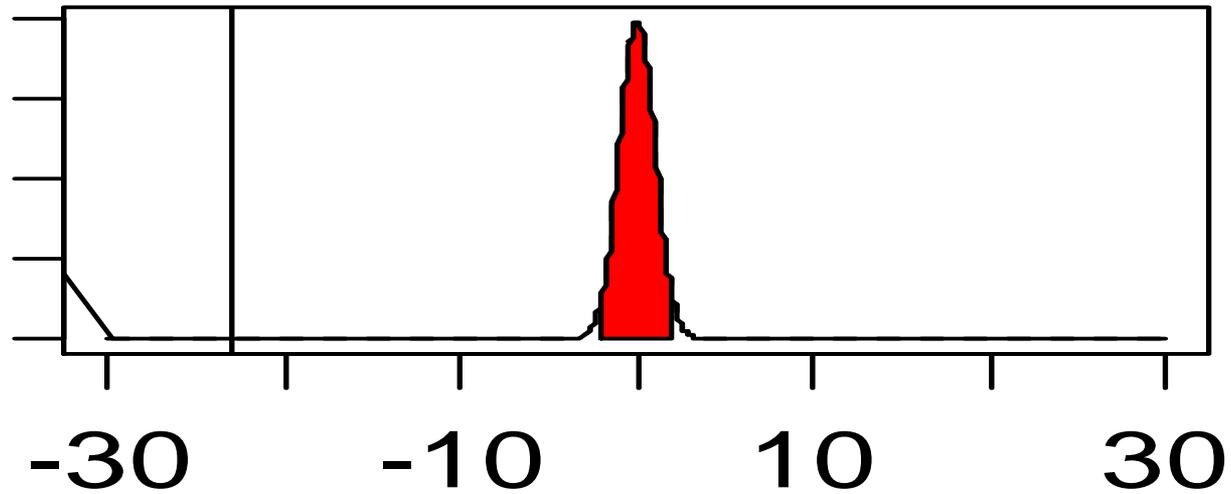
# KNN VS. ZeroR

## t Distribution

t = -24.06936

Density

0.3  
0.0



x value

# Pasos para hacer el contraste de hipótesis entre el algoritmo A y B

1.  $\{x_{ij}, y_{ij} \mid i=1:r, j=1:k\}$  son el error de la i-esima validación cruzada en el fold j-esimo.  $d_{ij} = x_{ij} - y_{ij}$

2. Calcular la media:  $\bar{d}_T = \frac{1}{r} \sum_{i=1}^{10} \frac{1}{k} \sum_{j=1}^{10} d_{ij}$

3. Calcular el estadístico t: ( $n_2=1/k, n_1=(k-1)/k$ )

$$t = \frac{\bar{d}}{\sqrt{\left(\frac{1}{k} + \frac{n_2}{n_1}\right) \sigma_d^2}}$$

4. Pvalue =  $1 - \text{prob}(|x| \leq t, t\text{-student con } df = r \cdot k - 1)$

$$\text{pvalue} = 1 - 2 * (1 - \text{pt}(\text{abs}(t), \text{df} = k * r - 1))$$

5. Si pvalue  $\leq 0.05$  entonces rechazar la hipótesis nula