

Inferencia Estadística

Clase 4 - Estadística Descriptiva

Paula Spano

Universidad Torcuato Di Tella



Estadística Descriptiva

(Bibliografía: Lock - cap 2: Describing Data)

Percentiles:

¿Cuál es el tiempo que es superado por el 30% de los usuarios?

`qnorm(0.7,60,4)` --> 62.0976




Medidas resumen


```
1  quantile(tiempo, probs = 0.7)
2      70%
3  61.88799
4
5  sort(tiempo)
6
7      [1] 52.13353 53.25323 53.80499 54.93841 54.93976 55.44745
8      [7] 55.50757 55.71284 55.72871 55.89598 55.92570 57.08444
9      [13] 57.22117 57.25259 57.49984 57.75810 57.77664 57.99071
10     [19] 58.10883 58.13338 58.21735 58.38846 58.47812 58.66717
11     [25] 58.77615 58.81971 59.07929 59.09692 59.12810 59.16833
12     [31] 59.66652 59.75235 59.82852 59.88581 60.21202 60.28203
13     [37] 60.44273 60.49542 60.51715 60.61349 60.86377 61.01327
14     [43] 61.21411 61.43926 61.51856 61.60309 61.70586 61.79284
15     [49] 61.84366 61.99140 62.21567 62.33845 62.75456 62.80542
16     [55] 63.11986 63.28632 63.35115 63.51253 63.58050 63.68907
17     [61] 64.83185 64.89633 65.01526 65.47441 66.06588 66.23483
18     [67] 66.86026 67.14765 68.20034 68.67582
19
20  n*0.7
21  [1] 49
22
23  0.7*61.84366+0.3*61.99140
24  [1] 61.88798
```

Medidas resumen

`qnorm(0.7,60,4) --> 62.0976`



`quantile(tiempo, probs = 0.7) --> 61.88799`



Definición

p_α : Es el **percentil muestral** $\alpha\%$ de un conjunto de datos y será el valor que deja aproximadamente el $\alpha\%$ de los datos a izquierda en la muestra ordenada.

Definición


Definimos como mediana al percentil muestral 50%, es decir aquel valor que deja aproximadamente el 50% de los datos a su izquierda. Si llamamos m a la mediana de un conjunto de n datos, entonces si n es impar, m es el valor central en el conjunto de datos ordenados y, si n es par, m es el promedio de los dos valores centrales en el conjunto de datos ordenados.

Medidas resumen

Mediana:

```
1  median(tiempo)
2  [1] 60.24703
3
4  sort(tiempo)
5  [1] 52.13353 53.25323 53.80499 54.93841 54.93976 55.44745
6  [7] 55.50757 55.71284 55.72871 55.89598 55.92570 57.08444
7  [13] 57.22117 57.25259 57.49984 57.75810 57.77664 57.99071
8  [19] 58.10883 58.13338 58.21735 58.38846 58.47812 58.66717
9  [25] 58.77615 58.81971 59.07929 59.09692 59.12810 59.16833
10 [31] 59.66652 59.75235 59.82852 59.88581 60.21202 60.28203
11 [37] 60.44273 60.49542 60.51715 60.61349 60.86377 61.01327
12 [43] 61.21411 61.43926 61.51856 61.60309 61.70586 61.79284
13 [49] 61.84366 61.99140 62.21567 62.33845 62.75456 62.80542
14 [55] 63.11986 63.28632 63.35115 63.51253 63.58050 63.68907
15 [61] 64.83185 64.89633 65.01526 65.47441 66.06588 66.23483
16 [67] 66.86026 67.14765 68.20034 68.67582
17
18 n*0.5
19 [1] 35
20
21 (60.21202 + 60.28203)/2
22 [1] 60.24703
```


Mediana:



La mediana es otra medida de la centralidad de los datos

- Mínimo valor muestral
- Primer cuartil: Es el percentil muestral 25%, y se denota como $Q_1 = p_{25}$
- Tercer cuartil: Es el percentil muestral 75%, y se denota como $Q_3 = p_{75}$
- Máximo valor muestral

Medidas resumen



Ejemplo - Tiempo de Lectura (Adaptación del Lock)

```
1  lectura <- read.table("lectura.txt", header = TRUE)
2  lectura
3
4  #      persona  tiempo
5  # 1          1        4
6  # 2          2        1
7  # 3          3        3
8  # 4          4       12
9  # 5          5        7
10 # 6          6        8
11 # 7          7       11
12 # 8          8       15
13 # 9          9       13
14 # 10         10       14
```

Los ordenamos:

```
1  x <- lectura$tiempo
2  sort(x)
3
4  # 1  3  4  7  8 11 12 13 14 15
```

y los graficamos:

Media muestral


Un posible valor que resume todos los datos



Media muestral: $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$


$\text{mean}(x) = 8.8$

Interpretación gráfica: centro de masa



Media muestral

Media muestral: $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$



- Medida de **centralidad** de un conjunto de datos
- Centro de masa o punto equilibrio
- Estimación de la esperanza.
- En R: `mean()`

Otra medida que agrega información

Varianza muestral:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

$$\text{var}(x) = 24.4$$


Desvío estándar muestral:

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2}$$


$$\text{sd}(x) = 4.9$$

Medidas resumen

Agreguemos a otra persona: `x_extra <- c(x, 80)`





Calculemos la media: `mean(x_extra) = 15.3`



¿La media es representativa del centro de los datos?

¿Cómo es respecto de la anterior (`mean(x) = 8.8`)?





- El persona nueva está haciendo un “efecto palanca”.
- La media muestral es muy sensible a “outliers” (datos atípicos).
- Queremos una medida de centralidad más “robusta”.

Otra medida de centralidad: mediana

La **Mediana** es un valor que deja aproximadamente la mitad de los datos a izquierda.

Calculemos la mediana en cada conjunto de datos. 

¿Cómo cambió la mediana al agregar a la persona extra?

¿Qué pasaría si la cantidad de horas que le dedica a la lectura la persona extra fuera 200 en lugar de 80?

La mediana es robusta a datos atípicos.

Definición

Si llamamos m a la mediana de un conjunto de n datos, entonces si n es impar, m es el valor central en el conjunto de datos ordenados y, si n es par, m es el promedio de los dos valores centrales en el conjunto de datos ordenados.

En R: `median()`

¿Qué medida de centralidad (posición) elegimos?

¿Qué medida de dispersión elegimos? Depende de qué medida de posición elijamos:

- Si informamos la media ($\bar{x}$), la medida de dispersión natural es el desvío estándar s .
- Si informamos la mediana (m), vamos a querer una medida de dispersión robusta.

¿El desvío estándar s es robusto?


`sd(x) = 4.9`

`sd(x_extra) = 21.97`

¿Por qué el desvío es sensible a datos atípicos?

¿Por qué el **desvío** es sensible a datos atípicos?

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$$




Queremos una medida de dispersión robusta, para ello vamos a utilizar los percentiles o cuantiles.

Otras medidas: percentiles (cuantiles)

Definición

p_α : Es el **percentil** $\alpha\%$ de un conjunto de datos y será el valor que deja aproximadamente el $\alpha\%$ de los datos a izquierda en el conjunto ordenado.

Calculemos los percentiles 10% y 90% en el ejemplo original.



```
quantile(x, probs = 0.1) = 2.8
```

```
quantile(x, probs = 0.9) = 14.1
```

```
quantile(x, probs = 0.5) = 9.5
```

5 medidas resumen




- Mínimo, máximo y mediana:

$\min(x) = 1$, $\text{median}(x) = 9.5$, $\max(x) = 15$

- dividen al conjunto de datos en dos
- permiten ver asimetría
- Cuartiles

Definición

$Q_1 = p_{25} \rightarrow$ *Primer cuartil* $Q_3 = p_{75} \rightarrow$ *Tercer cuartil*



- dividen cada mitad en dos:
- $\text{quantile}(x, \text{probs} = 0.25) = 4.75$
- $\text{quantile}(x, \text{probs} = 0.75) = 12.75$
- ¿Quién será Q_2 ?
- Q_1 y Q_3 encierran el 50 % central de los datos
- Junto con la mediana, permiten ver asimetría en el 50 % central de los datos.

5 medidas resumen en R

```
1 summary(x)
2 # Min. 1st Qu. Median Mean 3rd Qu. Max.
3 # 1.00 4.75 9.50 8.80 12.75 15.00
```

```
1 summary(x_extra)
2 # Min. 1st Qu. Median Mean 3rd Qu. Max.
3 # 1.00 5.50 11.00 15.27 13.50 80.00
```

Nos faltaba definir una medida de dispersión robusta.

Definición

La *distancia intercuartil* de un conjunto de datos es

$$IQR = Q_3 - Q_1$$

¿Por qué es una medida de dispersión?

¿Es robusta? ¿Por qué?

En R:

```
quantile(x, probs = 0.75) - quantile(x, probs = 0.25)  
= 12.75 - 4.75 = 8
```


```
IQR(x) = 8
```

```
IQR(x_extra) = 8
```


Medida	Fórmula	Función de R
media	$\frac{1}{n} \sum_{i=1}^n x_i$	<code>mean()</code>
desvío estándar	$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$	<code>sd()</code>
varianza	$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$	<code>var()</code>
percentil α	p_α	<code>quantile(, probs = $\frac{\alpha}{100}$)</code>
mediana	$m = p_{50}$	<code>median()</code>
1er cuartil	$Q_1 = p_{25}$	<code>quantile(, probs = 0.25)</code>
3er cuartil	$Q_3 = p_{75}$	<code>quantile(, probs = 0.75)</code>
dist. intercuartil	$IQR = Q_3 - Q_1$	<code>IQR()</code>
mínimo	$\min_{1 \leq i \leq n} \{x_i\}$	<code>min()</code>
máximo	$\max_{1 \leq i \leq n} \{x_i\}$	<code>max()</code>

Ejemplo: Tiempo de Lectura

Datos:



Agreguemos a otra persona: `x_extra <- c(x, 80)`



Dijimos que la persona extra es un dato atípico (**outlier**), pero, ¿cómo definimos formalmente cuándo un dato es un outlier?

Outlier: definición formal

Definición


Un dato x_i se considera un **outlier** en un conjunto de datos si

$$x_i < Q_1 - 1.5 IQR \quad \text{ó} \quad x_i > Q_3 + 1.5 IQR$$

La persona extra, ¿es un outlier?


$Q_1 = \text{quantile}(\text{x_hum}, \text{probs} = 0.25) = 5.5$

$Q_3 = \text{quantile}(\text{x_hum}, \text{probs} = 0.75) = 13.5$



Airquality

```
OzoneComp <- na.exclude(airquality$Ozone)  
n <- length(OzoneComp)  
n  
116
```




Airquality

```
OzoneMed <- summary(OzoneComp)
```

```
OzoneMed
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
1.00	18.00	31.50	42.13	63.25	168.00






Boxplot: Es un gráfico que se utiliza para visualizar la forma general del conjunto de datos, identificando el 50% de los centrales, los cuartiles y posibles datos atípicos.

Construcción:


- Dibujar una caja entre Q_1 y Q_3
- Dividir la caja con una línea a la altura de la Mediana
- Para representar los datos que NO son outliers: Dibujar una línea desde cada cuartil (Q_1 y Q_3) hasta la observación más extrema que no sea un dato atípico. (A estas líneas se las denomina bigotes)
- Marcar un punto por cada valor clasificado como outlier.

Airquality






Airquality - Histograma




Airquality - Histograma

Histogram of OzoneComp



Histogram of OzoneComp



Ejercicios de la práctica que pueden hacer

Práctica 2: - Ej. 6. y 7.