

Medidas de Tendencia Central y Dispersión

Dr. Delfino Vargas Chanes

Facultad de Economía
Universidad Nacional Autónoma de México

15 de febrero de 2024



Índice

1. Las Medidas
2. Medidas de Forma
3. Momentos y Código en R
4. Forma de la Distribución



Media Muestral

Definición 1.1 (Media Muestral)

La media de una muestra de n respuestas medidas x_1, x_2, \dots, x_n es dada por

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

La media de la población correspondiente se denota como μ

- La media muestral es el promedio de las observaciones en la muestra
- No es común poder medir la media de una población, μ es una constante desconocida que estimamos con muestras de la población.
- La media muestral se ve afectada por valores extremos
- La media es la suma de todas las observaciones dividida entre el número total de observaciones que participan en la suma.



Ejemplos de la Media

- Se tienen diez consultorios médicos y se registra el número de pacientes por consultorio. La media es:

$$\bar{x} = \frac{7 + 23 + 4 + 8 + 2 + 12 + 6 + 13 + 9 + 4}{10} = \frac{88}{10} = 0.88$$

- Excluyendo amistosos, Lionel Messi ha jugado 1,047 partidos, en los que ha metido 821 goles. La media de gol por partido de Messi es:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{821}{1,047} = 0.78$$

- Excluyendo amistosos, Cristiano Ronaldo ha jugado 1,204 partidos, en los que ha metido 873 goles. La media de gol por partido de CR7 es:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{873}{1,204} = 0.73$$



Media Ponderada

Definición 1.2 (Media Ponderada)

Sea una tupla de datos finita (x_1, \dots, x_n) y no vacía, con pesos asociados (w_1, \dots, w_n) y no negativos, definimos a la media ponderada como:

$$\bar{x} = \frac{\sum_{i=1}^n w_i x_i}{\sum_{i=1}^n w_i}$$

- La media ponderada es aquella que tiene asociados pesos.
- La media muestral es un caso particular de la media ponderada.



Ejemplos Media Ponderada

- Se desea estimar el número de productos vendidos en tres tipos de tiendas, repartidas en tres estratos. El peso probabilístico de cada estrato se indica por w_i ; Obtener la media y la media ponderada.

Tipo	Número de productos	w_i	Producto
Hipermercado	140	0.16	22.4
Supermercado	200	0.18	36.0
Mercado	163	0.21	34.2
		0.55	92.63

- Media Muestral:** 167.67
- Media Ponderada:** 168.42



Varianza

Definición 1.3 (Varianza)

La varianza de una muestra de resultados x_1, \dots, x_n es la suma del cuadrado de las diferencias entre los resultados y su media, dividido entre $n - 1$. Es decir,

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

La varianza poblacional asociada se denota por σ^2

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{N} \sum_{i=1}^n x_i^2 - N\mu^2 = \frac{\sum_{i=1}^n x_i^2}{N} - \mu^2$$

- La varianza mide la magnitud de la dispersión con respecto a una medida de tendencia central, por ejemplo, la media.
- Solo sirve para datos cuantitativos en escala intervalar o de razón.



Desviación Estándar

Definición 1.4 (Desviación Estándar)

La desviación estándar de una muestra de respuestas es la raíz cuadrada positiva de la varianza, es decir

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

La desviación estándar poblacional asociada se denota como $\sigma = \sqrt{\sigma^2}$



Ejemplo Varianza y Desviación Estándar en R

- Estaremos usando la librería **Applied Econometrics with R**
- Cargamos una base de datos utilizada en un paper publicado en el JPE sobre la infidelidad (Fair 1978).
- Variable numérica affairs \Rightarrow ¿Con qué frecuencia participó en relaciones sexuales extramatrimoniales durante el último año? 0 = ninguna, 1 = una vez, 2 = dos veces, 3 = 3 veces, 7 = de 4 a 10 veces, 12 = mensual, 12 = semanal, 12 = diariamente.
- ¿Que promedio y varianza tiene esta variable?



Ejemplo Varianza y Desviación Estándar en R

```
install.packages("AER")  
library(AER)
```

```
data("Affairs")  
range(Affairs$affairs)
```


```
mean(Affairs$affairs)  
[1] 1.455907
```

```
var(Affairs$affairs)  
[1] 10.8818
```

```
sd(Affairs$affairs)  
[1] 3.298758
```



La Dispersión



- La figura muestra la comparación tres distribuciones simétricas con diferente grado de dispersión. Tenemos $X \sim \mathcal{N}(3, 1)$, $X \sim \mathcal{N}(3, 0.7)$, y $X \sim \mathcal{N}(3, 0.6)$, donde definimos a $X \sim \mathcal{N}(\mu, \sigma^2)$.
- La desviación estándar y la varianza son dos medidas que miden la dispersión de una distribución de datos.



Datos de Ejecutivos

- Ejemplo se tienen datos de 81 ejecutivos que se encuentran en el archivo “ejecutivos.dta”, a los cuales se les miden la siguientes variables: Cuestionario, Caso, Planeación.
- Se desea obtener las Medidas de Tendencia central (media), mínimo, máximo. Medias de Dispersión: varianza, desviación estándar. Medias de Forma: Asimetría y Curtosis. (**TAREA: Reproducir en R**)

	Mín	Máx	Media	Desv.	Skew.	Curtosis
Cuest.	0	10	9.09	1.832	-2.396	7.019
Caso	1	10	6.99	2.519	-.329	-.781
Plan.	1	5	3.16	.798	.004	.776



Asimetría, Curtosis

Medidas de Forma

Buscan describir la función de distribución de frecuencias, indicando la simetría y curtosis.

Medidas de asimetría

Miden la simetría de la distribución de datos.


Medidas de curtosis

Miden la picudez de la distribución de datos.


- Si los datos tienen una distribución normal entonces cumplen que son simétricos con curtosis moderada (mesocúrticos).




Asimetría (Skewness)



$$S_k < 0$$



$$S_k \approx 0$$




$$S_k > 0$$



Curtosis


$$K > 3$$

Media, Mediana, Moda




$$K = 1$$

Media, Mediana, Moda



$$K < 3$$

Media, Mediana, Moda




Distribución leptocúrtica


Distribución mesocúrtica

Distribución platocúrtica







Sesgada a la izquierda




Simétrica




Sesgada a la derecha



Uniforme



Acampanada



Picuda



Sesgo y Curtosis

- La anterior gráfica nos enseña diferentes formas de curvas de densidad de probabilidad.
- En la primera fila, diferentes grados de simetría, y en la segunda, de picudez.
- Una curtosis alta es mayor que 1.0 o menor que 1.0
- Una asimetría alta es mayor que 1.0 o menor que -1.0
- La asimetría alta (en valor absoluto) y la curtosis alta (en valor absoluto), indican que las mediciones no tienen una distribución simétrica



Definición de Momentos

Definición 3.1

El k -ésimo momento central o centrado de una variable aleatoria x se define como

$$m_r = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^r$$

El primer momento central es 0, el segundo es la varianza (σ^2) donde σ es la desviación estándar. Podemos encontrar el tercer y cuarto momento en la definición de asimetría y de curtosis.



Curtosis: *psych* en R

- Para R la paquetería *psych* devuelve la curtosis.

Tipo 1: Definición típica utilizada en libros de texto antiguos:

$$g_2 = \frac{m_4}{m_2^2 - 3}$$

Tipo 2: Utilizada en SAS, SPSS, STATA y EXCEL:

$$G_2 = \frac{[(n-1)g_2 + 6](n-1)}{(n-2)(n-3)}$$

Tipo 3: Utilizado en MINITAB y BMDP:

$$b_2 = \frac{m_4}{s^4} - 3$$



Curtosis y Asimetría: *moments* en R

- Para la paquetería *moments* solo hay una manera de calcular la asimetría, que es igual al **Tipo 1** para *psych*, en la que se usa la definición típica en los libros de texto, la formula es dada por:

$$g_2 = \frac{m_4}{m_2^2 - 3}$$

- La Curtosis para la paquetería *moments* calcula el estimador de la medida de curtosis de Pearson más 3. Quiere decir que nos da el valor exacto de la curtosis y no el exceso.

$$K_p = \frac{m_4}{m_2^2} + 3$$



¿Por qué existen diferencias entre *psych* y *moments*?

- A lo largo de los años, se han propuesto varias medidas de asimetría y curtosis para muestras, en donde la mayoría difieren en su error cuadrático medio y en el sesgo.
- Diversos autores han sugerido que la asimetría y la curtosis deben verse como “conceptos vagos” que pueden formalizarse de muchas maneras (Groeneveld 1998). Se han sugerido definiciones distintas.
- Entonces, de acuerdo con los autores de la paquetería *psych* (Joanes y Gill 1998) para muestras grandes, hay muy poco que elegir entre las distintas medidas ya que la diferencia entre los valores se vuelve insignificante. El problema radica cuando nos enfrentamos a muestras pequeñas en donde las diferencias pueden ser bastante sorprendentes.



Cálculo de Asimetría y Curtosis en R

```
install.packages("psych")  
install.packages("moments")  
library(moments)  
library(psych)
```

```
x<- c(6.3, 7.3, 7.3, 7.5, 7.8, 8, 8.1, 8.5, 8.6, 10)
```

```
#Usando la libreria psych
```

```
psych::kurtosi(x,na.rm = TRUE, type = 1)  
psych::kurtosi(x,na.rm = TRUE, type = 2)  
psych::kurtosi(x,na.rm = TRUE, type = 3)  
describe(x,type=1)  
describe(x,type=2)  
describe(x,type=3)
```



Cálculo de Asimetría y Curtosis en R

```
install.packages("psych")
install.packages("moments")
library(moments)
library(psych)

x<- c(6.3, 7.3, 7.3, 7.5, 7.8, 8, 8.1, 8.5, 8.6, 10)

#Usando la libreria moments

moments::skewness(x)
moments::kurtosis(x)
```



Resultados (Comprobar con R)

Tipo	Skewness	Curtosis
1	0.51	0.3880583
2	0.61	1.650317
3	0.44	-0.2556727
Moments	0.5119674	3.388058

- Estos resultados los podemos encontrar con otros programas estadísticos como Excel, STATA, SPSS, pero el enfoque práctico de este curso es el uso de RStudio.

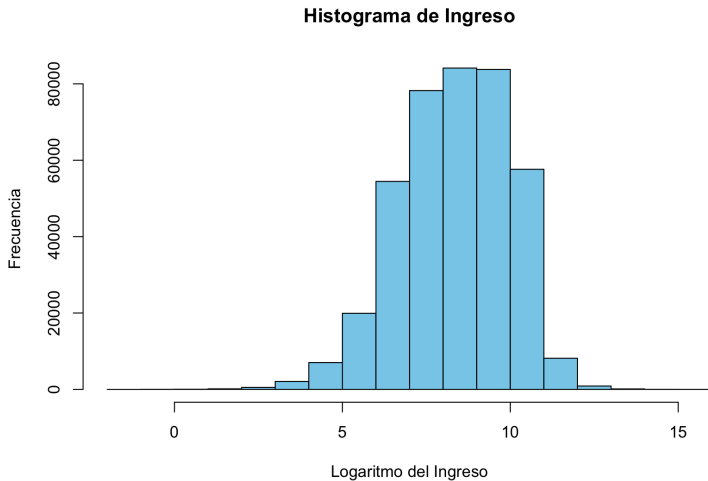


Algunas consideraciones

- La mediana puede inclusive coincidir con los cuartiles o con los límites de los bigotes.
- Esto sucede cuando se concentran muchos datos en un mismo punto, en este caso, muchas personas tienen los mismos puntajes. Pudiera ser este un caso particular de una distribución sesgada o el caso de una distribución muy homogénea.
- En seguida se muestra el histograma de frecuencias correspondiente de los mismos datos que el diagrama de caja de la presentación pasada.



Histograma en R



Código en R

```
library(ggplot2)
theme_set(theme_bw())

hist(log_ingreso,
     main = "Histograma de Ingreso",
     ylab = "Frecuencia",
     xlab = "Logaritmo del Ingreso",
     col = "skyblue",
     border = "black"
)

summary(log_ingreso)
quantile(log_ingreso)
describe(log_ingreso)
```



Bibliografía

- Bhattacharyya, G. K., y Johnson, R. A. (1977). *Statistical concepts and methods*. Wiley.
- Bickel, P. J., y Doksum, K. A. (2015). *Mathematical statistics: basic ideas and selected topics, volumes i-ii package*. CRC Press.
- Fair, R. C. (1978). A theory of extramarital affairs. *Journal of political economy*, 86(1), 45–61.
- Groeneveld, R. A. (1998). A class of quantile measures for kurtosis. *The American Statistician*, 52(4), 325–329.
- Joanes, D. N., y Gill, C. A. (1998). Comparing measures of sample skewness and kurtosis. *Journal of the Royal Statistical Society: Series D (The Statistician)*, 47(1), 183–189.
- Wackerly, D., Mendenhall, W., y Scheaffer, R. L. (2014). *Mathematical statistics with applications*. Cengage Learning.



¡Gracias por su atención!

