

ESTADÍSTICA Y PROBABILIDADES

TOMO 1

NOCIONES BÁSICAS DE ESTADÍSTICA ;
COMPRENDIENDO LOS DATOS



Jorge Galbiati Riesco

ESTADÍSTICA Y PROBABILIDADES.

Tomo 1: Nociones básicas de Estadística; comprendiendo los datos.

Segunda edición 2022

Jorge Mauricio Galbiati Riesco, Ph.D.

Instituto de Estadística

Pontificia Universidad Católica de Valparaíso.

ILUSTRACIONES: Paola Galbiati Valverde, Diseñadora gráfica.

www.talleronce.cl

AGRADECIMIENTOS: A la Doctora en Ciencias Pamela Reyes Santander, Coordinadora de Matemática, Unidad de Currículum y Evaluación, Ministerio de Educación, Gobierno de Chile. Por la revisión del original y por sus valiosas sugerencias.

PORTADA: Calendario maya y números maya. Los mayas inventaron el cero en forma independiente a su invención en la India, de donde pasó a Arabia y de ahí a Europa. El cero lo representaban por un caracol. Diseño del autor.

ESTADÍSTICA Y PROBABILIDADES

TOMO 1: NOCIONES BÁSICAS DE ESTADÍSTICA; COMPRENDIENDO LOS DATOS

Segunda edición 2022

Contenido

| | |
|---|-----|
| 1. Introducción | |
| <i>Resumiendo información.</i> | 7 |
| 2. La Estadística | |
| <i>¿Qué es la Estadística?</i> | 9 |
| 3. Las mediciones | |
| <i>Conocer es medir.</i> | 11 |
| 4. Poblaciones y muestras | |
| <i>El todo y una parte de él.</i> | 20 |
| 5. Selección al azar con y sin reposición | |
| <i>¿Cómo me aseguro que la muestra representa la población?</i> | 27 |
| 6. La variación | |
| <i>Nada es constante.</i> | 32 |
| 7. Gráficos de barra e histogramas | |
| <i>Un gráfico dice más que mil palabras.</i> | 37 |
| 8. Medidas de centro: la media y la mediana | |
| <i>Todo gira en torno al centro.</i> | 52 |
| 9. Medidas de posición. Los percentiles | |
| <i>El centro y otros lugares.</i> | 59 |
| 10. El diagrama de cajón con bigotes | |
| <i>Una alternativa a los histogramas.</i> | 67 |
| 11. Medidas de dispersión | |
| <i>¿Mis datos, cuán distintos son entre ellos?</i> | 83 |
| 12. Medidas de asociación entre variables | |
| <i>¿Cada una por su lado, o tienen alguna vinculación?</i> | 94 |
| Apéndice 1 - Uso de Microsoft Excel | 130 |
| Apéndice 2 - Uso de R | 133 |
| Explicación acerca de las franjas de colores | 149 |
| Índice alfabético | 151 |

Presentación

El currículum escolar chileno en Matemática busca desarrollar las habilidades, actitudes y conocimientos en todos los ejes de la asignatura: números, álgebra y funciones, geometría y probabilidad y estadística. Para comprender las matemáticas y ser capaz de aplicar sus conceptos y procedimientos es necesario trabajar en conjunto con las habilidades de la asignatura: resolver problemas, representar, modelar, argumentar y comunicar, que se desarrollan a lo largo de los doce años de escolaridad, desde el primero básico hasta el cuarto medio. El espíritu de la Ley General de Educación nos moviliza a proponer y promover de una manera didáctica el aprendizaje de las habilidades y conocimientos matemáticos. También, nos mueve a generar y apoyar iniciativas que tienen como principio el aprendizaje de conocimientos expertos, con contenidos cercanos a los estudiantes y tratados en un lenguaje adecuado para ellos, donde prevalece un objetivo común, que es poner en práctica en las aulas el desarrollo de habilidades y la comprensión del conocimiento para participar con información y de manera propositiva en la vida del país. La Matemática entrega herramientas únicas y poderosas para entender el mundo. Bajo este gran objetivo, la Unidad de Currículum y Evaluación del Ministerio de Educación de Chile, ha generado recursos pedagógicos y herramientas que promueven el desarrollo de conocimientos y habilidades para el eje de ESTADÍSTICA, entendiendo que los objetivos de aprendizaje de las Bases Curriculares se desarrollan de manera progresiva y en armonía con el nivel etario de los estudiantes. Para los expertos del área de matemática de esta Unidad ministerial, los conocimientos sobre estadística permiten al estudiante recopilar, procesar y organizar datos, también comprender en qué situaciones de la vida diaria es relevante aplicar los conocimientos estadísticos para poder resolver problemas, comunicarse con otros, entender la información de los

medios de comunicación e interpretar en base a los datos presentados u obtenidos directamente. En pocas palabras, las Bases Curriculares promueven el pensamiento estadístico. En este contexto y especialmente dirigido a los niveles de sexto básico a segundo medio, el autor de este libro, en un acto de generosidad para los escolares y profesores de Chile, ha dedicado su tiempo a escribir de manera amable con el lector, y con una sabiduría que se lee desde las primeras páginas, para dejar su legado de muchos años de enseñanza de la estadística, en beneficio no solo de los profesores y estudiantes de nuestro país, sino también de los hispanoparlantes del mundo. Estadística y Probabilidades Tomo 1 Nociones básicas de estadística: conociendo los datos

10 Este libro es una contribución en formato electrónico, que estará disponible en las plataformas digitales del Ministerio de Educación, y representa un gran aporte para la comprensión de las nociones básicas de estadística y su trabajo en aula. El autor ha procurado llevar sus pensamientos de lo que es la estadística y su forma de comprender los conceptos, de manera agrandable y fácil de seguir, ejemplificando y haciendo ver que todo es muy sencillo si se mira de una forma particular. En sus diferentes secciones, muestra el significado de trabajar con las planillas de cálculo para facilitar el trabajo y aprovechar las herramientas disponibles y así poder concentrarse en dar significado a los conceptos y dejar lo más relevante de la información estadística. Como directora de la Unidad de Currículum y Evaluación del Ministerio de Educación de Chile y además profesora de matemática y física, es un enorme gusto presentarles el título del primer tomo de la serie de **Estadística y Probabilidades “Nociones Básicas de Estadística; comprendiendo los datos”** porque estoy convencida que es y será un aporte significativo para todos los escolares y para las actuales y futuras generaciones de profesores de nuestro país. Los invito a todos a leer y sacar el máximo provecho a todas las ideas aquí presentes, llevar las actividades a sus clases y ajustarlas según sus necesidades contextuales. Finalmente, aprovecho la oportunidad de ofrecer una sincera felicitación y reconocimiento por el trabajo de investigación y recopilación realizado por el autor del libro, don Jorge

Galbiati, y transmitir también el agradecimiento del Ministerio de Educación de Chile por conceder los permisos de publicación de esta obra, de manera gratuita, en la plataforma Currículum Nacional de la Unidad de Currículum y Evaluación.

María Isabel Baeza Errázuriz

Coordinadora Nacional Unidad de Currículum y Evaluación

MINISTERIO DE EDUCACIÓN

Santiago, noviembre 2021.

1. Introducción

Resumiendo información.

No hay una definición del término **Estadística** que satisfaga a todos.

Pero algunos dicen que es el arte de **resumir información**, lo que parece una definición muy breve, pero como aproximación, parece ser acertada.

Sin embargo, es muy general, y puede aplicarse también a otras áreas del conocimiento.

¿Para qué resumimos la información que tenemos? Para entenderla mejor, a costa de perder una parte de la **información**.

Los humanos no tenemos capacidad de entender grandes o medianamente grandes volúmenes de información.

Para que la información sea realmente útil, debemos poder entenderla bien, y para eso, es necesario resumirla.

¿Cuánto resumir? Mientras más se resume, más fácil es entenderla, pero hay más pérdida de información.



Hay que buscar un equilibrio entre la facilidad de comprensión que queremos y la cantidad de información que queremos conservar.

EJEMPLO 1

Promedios de notas.

Si tus notas en una asignatura son 5,2; 6,1; 4,8; 6,8; 5,4; 6,2.

El promedio es $34.5/8=5,75$

Si alguien te pregunta cómo te está yendo en esa asignatura puedes comunicar tus 6 notas, es decir, responderle que tienes 5,2; 6,1; 4,8; 6,8; 5,4; 6,2.

O bien, simplemente decir que tienes un promedio de 5,75.

En el segundo caso estás dando menos información, pero está comunicando con más claridad el nivel de éxito que tienes en la asignatura.

¿Cómo resume información la Estadística?

La forma más simple es a través de **tablas** y **gráficos**.

Otra forma de resumir es mediante el uso de **medidas** o **indicadores**, que se calculan con los datos. Por ejemplo, el promedio.

Una manera más compleja consiste en desarrollar **modelos estadísticos**, que en términos simples son capaces de describir razonablemente bien una situación real. Son una aproximación de la realidad.

Conociendo el modelo y algunas de sus características, llamadas parámetros, se puede entender mejor el comportamiento del fenómeno real.

2. La Estadística

¿Qué es la Estadística?

La Estadística normalmente extrae información de conjuntos de **datos**, que fueron generados de algún conjunto muy grande de datos, que llamaremos población objetivo o simplemente **población**. Estos conjuntos pueden ser pequeños o muy grandes.

La importancia de los datos en la obtención de información está reflejada en una frase que hemos pedido prestado de quienes se dedican al tema de la **Calidad**. Dice así: "*A Dios le creemos; los demás, que traigan datos*".

De esos datos la Estadística, a través de sus **métodos propios**, es capaz de extraer **información** acerca de la población.

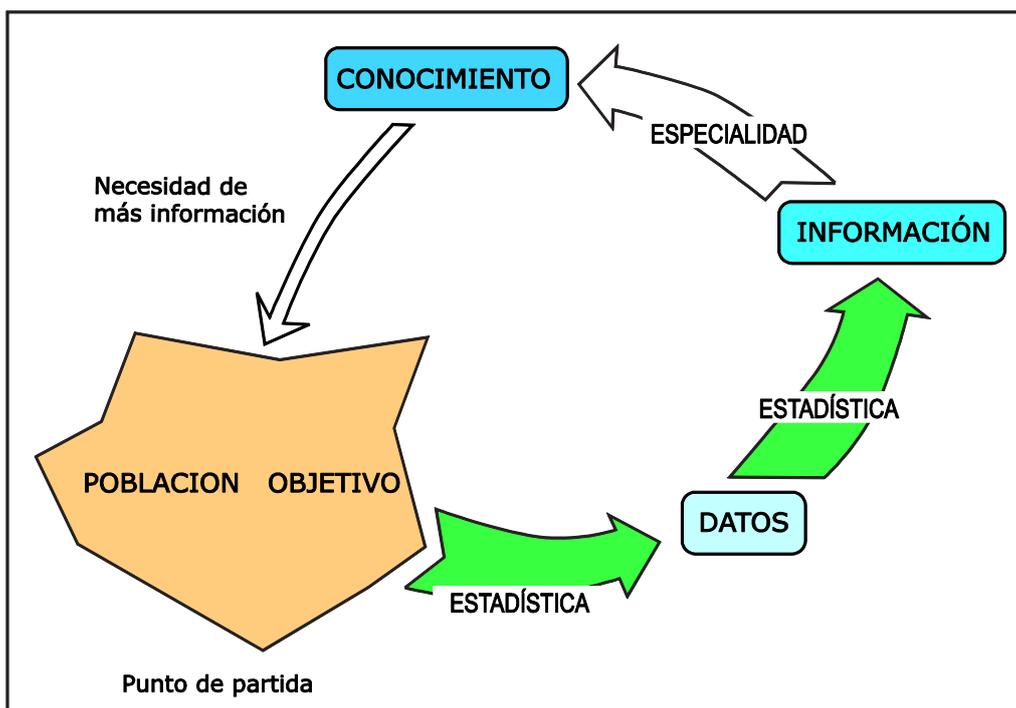
La Estadística también interviene en el proceso de **adquisición** de los datos de donde luego extraerá la información.

Esta información es útil a la hora de tomar **decisiones**.

Quien debe tomar decisiones es un especialista en el tema bajo estudio, lo que él o ella hace es usar sus recursos intelectuales, para agregarle valor a la información y transformarla en **conocimiento** acerca de la población objetivo, que es la información convertida en algo útil.

Este conocimiento sobre la población permitirá reducir la incertidumbre al momento de tomar alguna decisión.

Esto está representado en el siguiente gráfico:



Frecuentemente ese conocimiento conduce a la necesidad de obtener más datos. Que luego aportarán nueva información, que a su vez proveerá más conocimiento.

Y de esa manera el proceso sigue repitiéndose hasta lograr un **conocimiento profundo** del fenómeno sobre el que se deberá **tomar decisiones**.

3. Las mediciones

Medir es conocer.

Muchas veces hemos medido algo. Pero, ¿qué es medir?

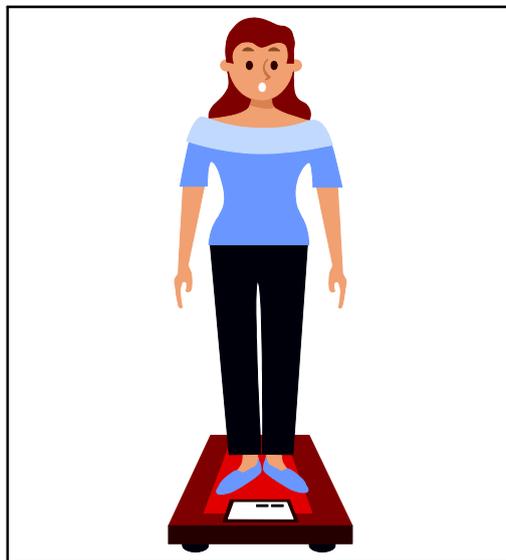
Daremos una definición sencilla de la acción de medir:

Medir es observar una **característica** y asignarle un **número** o una **categoría**.

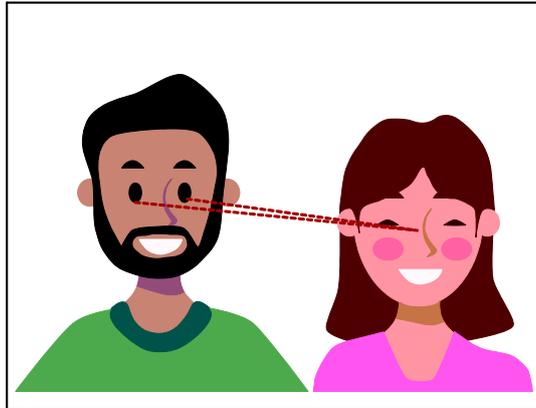
EJEMPLO 2

Medidas.

Si subes a una pesa y ves que marca 50 kilos, eso es medir. Asignaste un número al peso.



Si observas el color de ojos de tu compañera y determinas que son verdes, también estás midiendo: asignas una categoría, verde.



En el primer caso usaste una **escala de medida numérica**. En el segundo ejemplo usaste una **escala de medida categórica**.

Más adelante nos referiremos a eso.

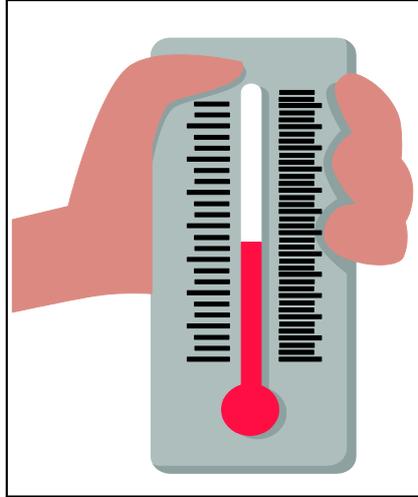
Las escalas de medida numéricas son mejores que las categóricas, pues nos dan información más precisa sobre la característica que estamos midiendo.

Entre las medidas en escala numérica observamos que hay fenómenos que tienen características con valores positivos y negativos.

EJEMPLO 3

Medidas con valores positivos y negativos.

Si se toma la temperatura ambiental seguramente resultarán valores positivos; pero en lugares muy fríos, como Puerto Natales en invierno, pueden resultar temperaturas menores que cero, como, por ejemplo, menos cinco grados centígrados.



Si alguien tiene un emprendimiento y al final del mes calcula sus utilidades, ésta podría ser positiva, como también podría tener la mala suerte de haber obtenido una utilidad negativa, se llama pérdida.

Pero hay otros fenómenos que sólo toman valores positivos. Esto sucede en la mayoría de los casos.

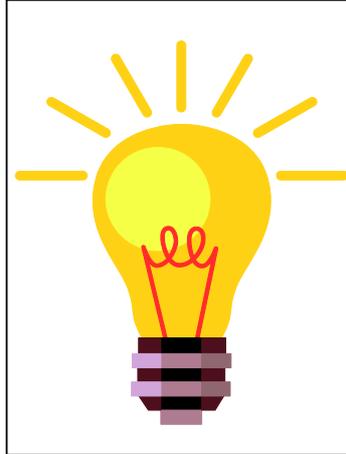
EJEMPLO 4

Medidas sólo con valores positivos.

Algunas características que tienen sólo valores positivos:

Si mides la altura de tus compañeros, su peso, su edad.

El tiempo de vida de una ampolleta, hasta que se quema, la distancia recorrida por un vehículo, el diámetro de unos tornillos, entre muchas otras medidas numéricas.



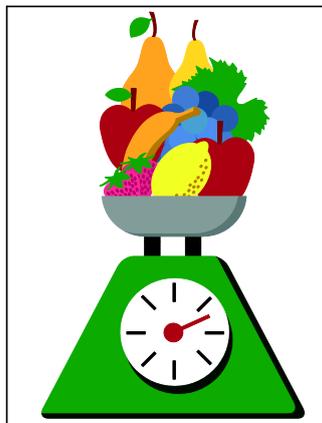
Un **instrumento de medida** es un elemento sensible a lo que se desea medir.
El instrumento permite medir.

EJEMPLO 5

Medida fáciles y difíciles de obtener.

Una regla graduada o una huincha de medir sirve para medir longitudes de objetos.

Un examen médico de laboratorio se usa para medir el contenido de ciertos compuestos químicos en algún órgano de una persona.



Una balanza es para medir el peso de la fruta que estás comprando.

Pero hay cosas más difíciles de definir y de medir:

Una encuesta se puede usar para conocer la opinión de un cliente acerca de un servicio que recibió.

La opinión de los jueces en un concurso de saltos ornamentales sirve para medir el desempeño de cada uno de los deportistas que participan en él.

Una prueba de Biología le sirve al profesor para saber cuánto han aprendido sus estudiantes.

Una **escala de medida** es un conjunto de valores con los cuales se expresa una **variable en estudio**.

En una primera clasificación hay dos tipos de escalas de medida: **numéricas** y **categóricas**.

Las **numéricas**, como lo dice su nombre, están constituidas por números.

Las **escalas** categóricas están constituidas por objetos que no son números, sino por **categorías**.

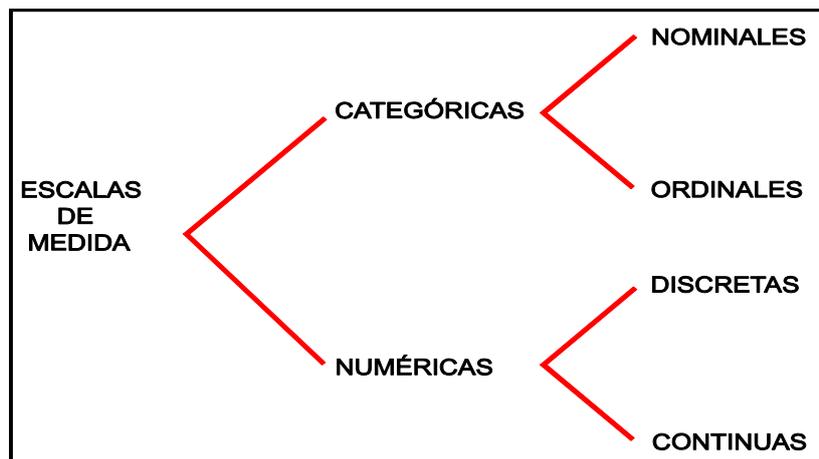
Si una **escala categórica** tiene un **orden natural**, se llama **categórica ordinal**. Si no lo tiene, se llama **categórica nominal**.

Las variables numéricas se pueden dividir en **discretas** y **continuas**.

Las **discretas** son las escalas que son **finitas**, como $\{1, 2, 3, 4, 5, 6\}$. Pero también pueden ser **infinitas**, pero sus elementos se pueden **enumerar**: el primer elemento, el segundo, el tercero,... No tienen límite.

Y las escalas **continuas** son escalas numéricas que son intervalos de números reales. Por eso son **infinitas** y **no se pueden enumerar**.

Este es un concepto bastante **abstracto**. No es fácil imaginarse un conjunto de valores con esa característica.



Si una variable se mide en escala discreta, se dice que es una **variable discreta**.

Si se mide en escala continua, se dice que es una **variable continua**.

Hay casos especiales de escalas, numéricas o categóricas, que sólo tienen dos valores. Se denominan **dicotómicas** o **binarias**.

EJEMPLO 6

Escalas de medida nominales y numéricas.

Tenemos muchos ejemplos de variables categóricas, como los siguientes conjuntos:

Las marcas de automóviles. En general no tienen orden, **son nominales**.

los colores, que son **nominales**, no hay un orden natural.

los meses del año, que son ordinales porque tienen un **orden**.

{bueno, regular, malo}; esta escala tiene un orden natural, es **ordinal**.

{alto, mediano, bajo}; tiene orden, es **ordinal**.

El orden alfabético es arbitrario, así que estrictamente no dan un orden natural.

Eso es porque el orden en que están las letras del alfabeto se lo dieron arbitrariamente quienes lo crearon.

Puede que en otro alfabeto distinto al que estamos usando aquí, el orden sea diferente.

Ejemplos de conjuntos de medidas **numéricos finitos** pueden ser $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10\}$, o bien $\{3; -6; -3,9; 25,8\}$. En este último separamos los números con punto y coma, para que no haya confusión con la coma decimal.

Las escalas numéricas continuas tienen la siguiente particularidad: si tomamos un número cualquiera del conjunto, **no hay un número siguiente**.

Por ejemplo, tomemos el 3,456. ¿Cuál es el siguiente? No tiene. Si alguien dice que es el 3,457, resulta que no es el siguiente. Porque antes de este último hay muchos, como el 3,4565 entre otros.

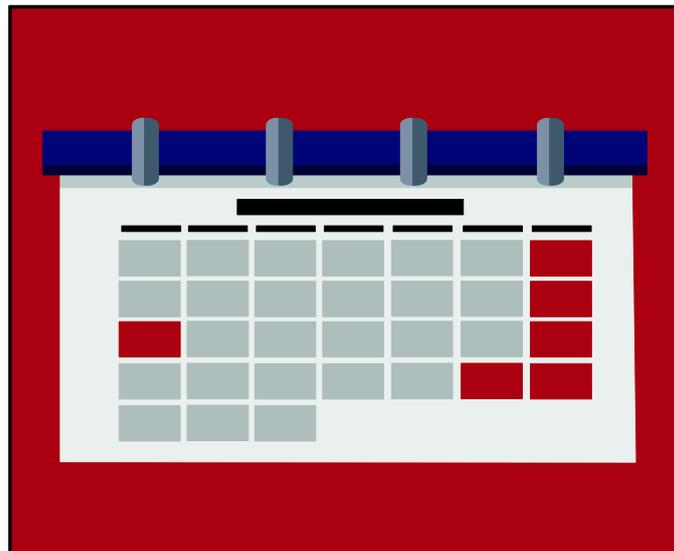
Cada vez que tengamos dos números de una escala **continua**, podremos encontrar uno que está entre ellos. En realidad, hay **infinitos** números reales entre el 3,456 y el 3,457. Y no se pueden enumerar.

Considera, por ejemplo, un número real muy especial, **pi**, que seguramente conoces. Es el cociente entre el perímetro de un círculo dividido por su diámetro. $\pi = 3,14192653589793\dots$ ¡ tiene infinitos decimales !

EJEMPLO 7

Medidas expresadas en escalas categóricas.

Si observas el mes de nacimiento de un grupo de personas, tienen orden, por lo que estás usando una escala de medida categórica ordinal.



Si registras la actividad laboral de las mismas personas, como arquitecto, jornalero, suplementero, enfermera, vendedora, etc., no tienen un orden natural.

El orden alfabético es arbitrario; en otras culturas el orden de las letras, que representan sonidos emitidos por la boca, es distinto.

EJERCICIOS

- 1) En un condominio se contó el número de niños y niñas menores de 13 años por vivienda.

Indica y clasifica el tipo de la variable que se está midiendo: si es numérica discreta, numérica continua o categórica.

2) En cada caso indica una variable que mida alguna característica de los estudiantes de tu establecimiento educacional, y que se clasifiquen como:

- a) numérica continua
 - b) numérica discreta
 - c) categórica.
-

4. Poblaciones y muestras

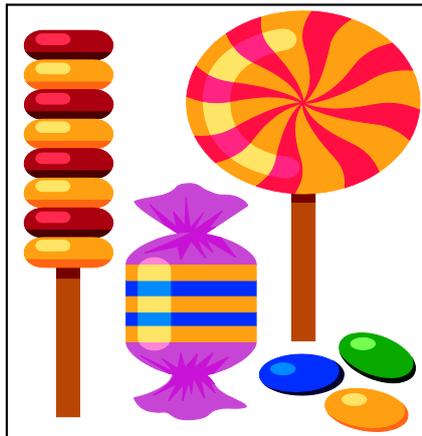
El todo y una parte de él.

Siempre que queremos estudiar algo y descubrir qué propiedades tiene, nuestras conclusiones se refieren a una parte de la realidad que nos rodea.

EJEMPLO 8

Podemos observar sólo una parte de lo que nos interesa conocer.

Si quieres averiguar qué piensan tus compañeros acerca de hacer un paseo el sábado próximo, lo que logres averiguar se referirá a la totalidad de tus compañeros. Pero sólo le preguntarás a algunos.



Si una fábrica de caramelos quiere saber cuál será la aceptación que tendrá un nuevo tipo de bombón que quiere introducir, llevará a cabo un estudio de mercado, y los resultados que obtenga se referirán al público a quienes querrá vender su nuevo producto.

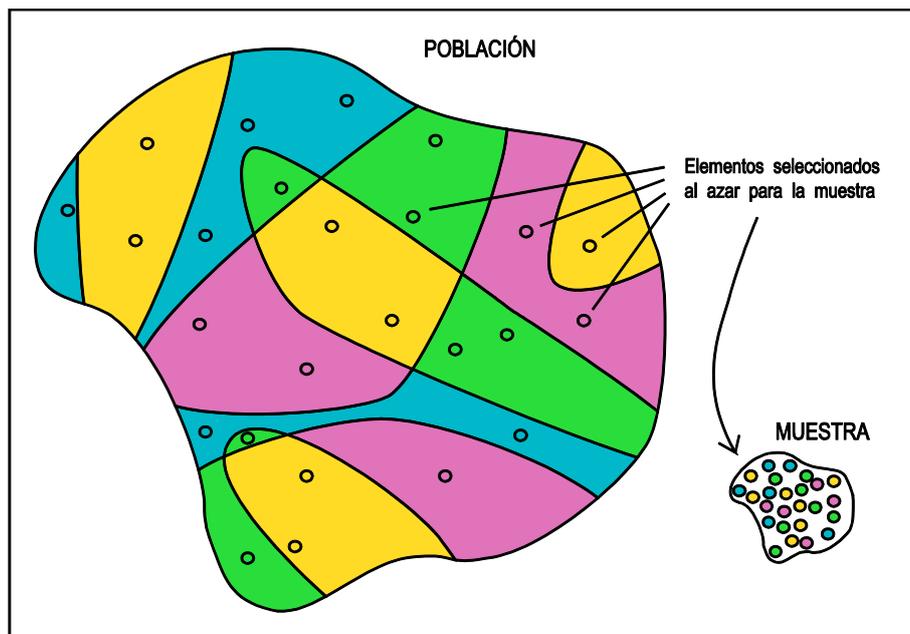
Pero no le puede preguntar a todos los posibles consumidores de bombones.

Como dijimos antes, el conjunto de todas las personas o todas las cosas a las cuales se refiere un estudio, se denomina **población** o bien **población objetivo**.

Las poblaciones suelen ser **muy grandes**, por ejemplo, los consumidores, en todo el país, de una determinada marca de jabón.

Por eso, para hacer un estudio, se suele observar sólo una fracción de la población. Esta se llama **muestra**.

La muestra, si es **representativa**, puede considerarse como una **miniatura** de la población.



Para que el estudio de una población, a través de una muestra, sea verdaderamente válido, la muestra debe ser **representativa** de la población.

Una condición que debe cumplir es que sea seleccionada **aleatoriamente**, o **al azar**. De esa manera evitamos introducir patrones que pueden distorsionar los resultados del estudio que queremos hacer.

Estrictamente, las poblaciones y las muestras están formadas por las **medidas** de la variable en estudio y no por los **sujetos** que son medidos.

Sin embargo, en este contexto consideraremos las poblaciones y las muestras constituidas por los sujetos.

La característica de la población que medimos, porque es la que nos interesa estudiar, se llama **variable en estudio**.

Por ejemplo, si en un momento dado se mide la temperatura de un compuesto en una reacción química, la variable en estudio es la temperatura que se observa.

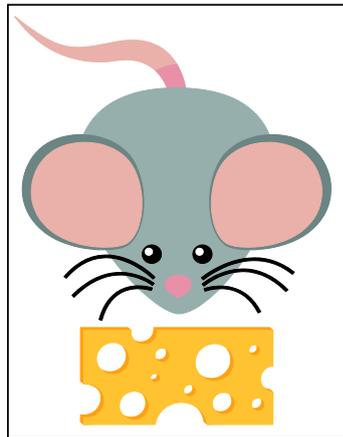
Otra situación puede ser la siguiente: se asignan temas a los estudiantes de un curso para que escriban composiciones sobre ellos; el profesor quiere medir el **grado de creatividad** de los estudiantes.

Sea como fuere la forma como el profesor la medirá, es la **creatividad** lo que le interesa. Esa es la **variable en estudio**.

La **variable en estudio** se puede medir en cualquiera de las escalas de medida que introdujimos antes: numérica, discreta o continua, o bien categórica, nominal u ordinal.

EJEMPLO 9

Efecto de un agente patológico en ratones.



Un investigador examina los efectos de un agente patológico presente en un determinado alimento, en ratones.

Tiempo después, durante el cual los ratones consumieron dicho alimento, el investigador los examina para detectar presencia o ausencia de posibles indicios de la patología.

Identificaremos la población objetivo, la muestra, la unidad experimental, la variable en estudio, el tipo de variable y la escala de medida.

La población objetivo es el conjunto de los ratones del tipo a que se refiere el resultado del estudio.

La muestra es el grupo de ratones usados en el experimento.

La variable en estudio es la presencia o ausencia de la patología.

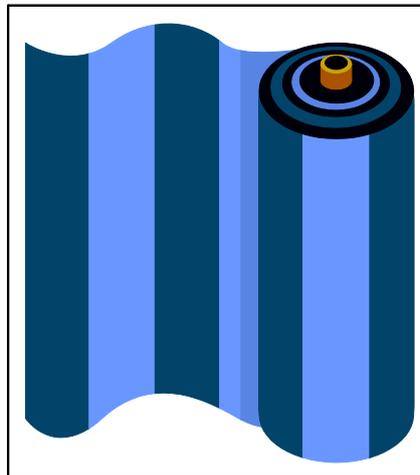
Los datos son las medidas tomadas a los ratones. En este caso se mide si tienen o no tienen la particular patología.

Es una variable **categorica**, es decir, **no numerica**, tiene dos valores posibles: tiene o no esa patología. Este tipo de variable con dos valores suele llamarse **dicotomica**.

EJEMPLO 10

Industria textil.

Un inspector de control de calidad en una industria textil selecciona y examina, en varios momentos de un día, piezas de género producidos, pesando la pieza y calculando el peso por metro.



Le interesa verificar que sea lo más uniforme posible.

La **población objetivo** consiste en todas las piezas de género similares producidas en esa industria.

La **muestra** consiste en todas las piezas seleccionadas y examinadas por el inspector de calidad.

La **variable en estudio** es lo que mide el inspector para verificar la calidad, el peso por metro.

En este caso la variable en estudio es el peso por metro, medida en escala numérica, y los datos son los valores numéricos de las medidas obtenidas por el inspector de control de calidad.

EJERCICIOS

3) Se desea saber si un sistema nuevo de enseñanza de Lenguaje tiene un efecto beneficioso sobre el aprendizaje de los alumnos.

Se aplica este nuevo sistema durante un año escolar en 10 cursos seleccionados por sorteo, separadamente en escuelas básicas de la comuna San Fabián.

Al final de año se aplicará una evaluación. Identifica:

- a) la población objetivo
- b) la o las variables involucradas en el estudio.

4) Se desea estimar el gasto promedio, por vivienda, en combustible durante los últimos tres meses, en una ciudad de tamaño pequeño.

Para ello se seleccionan 362 viviendas, al azar, y en cada una se pregunta por el gasto en combustible. Se sabe que en total hay 27.640 viviendas.

Identifica:

- a) la variable que se interesa medir
 - b) la población objetivo.
- 5) Indica dos variables que midan alguna característica de un estudiante típico de tu colegio, y que se clasifiquen como:
- a) continua
 - b) discreta

- c) categórica.
 - 6) Identifica y clasifica las variables involucradas en los siguientes estudios:
 - a) Estructura por sexo y edad de la población del país
 - b) número de hijos por familia en las provincias de un país
 - c) mortalidad por causa de muerte
 - d) proporción de individuos de una población diagnosticados como extrovertidos, en un estudio psicológico
 - e) tiempo, en centésimas de segundo, entre el inicio de la llegada de dos mensajes consecutivos en un sistema de comunicación electrónico
 - f) palabras leídas en 15 segundos, por una muestra de individuos.
-

5. Selección al azar con y sin reposición.

¿Cómo me aseguro que la muestra representa la población?

MOTIVACIÓN

En las encuestas de opinión se supone que la selección de las personas a las que se les pide que respondan la encuesta, a través de un cuestionario, se hace **al azar** y **sin reposición**.



Sin reposición significa que, si alguna persona respondió la encuesta, a ella no se le pedirá otra vez que responda el mismo cuestionario.

Ya no volverá a salir seleccionada en la muestra.

Hay varias formas de elegir una muestra aleatoria; distinguimos dos de ellas: selección **con reposición** y **selección sin reposición**.

Selección de una muestra al azar **con reposición** significa que, si sale seleccionado un elemento de la población, podría volver a ser seleccionado, si por el azar eso sucediera.

Mientras que en la elección de una muestra al azar **sin reposición**, una vez que un elemento es seleccionado, ya no puede serlo otra vez.

EJEMPLO 11

Alturas de estudiantes.

Supongamos que tenemos la siguiente población, consistente en las alturas, en centímetros (cm), de un grupo de 30 alumnos de Primer Año Medio:

| | | | | | | | | | |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 146 | 175 | 147 | 143 | 170 | 172 | 177 | 162 | 160 | 164 |
| 185 | 151 | 180 | 161 | 152 | 171 | 182 | 163 | 181 | 169 |
| 148 | 184 | 166 | 157 | 176 | 156 | 149 | 178 | 153 | 168 |

Esta es nuestra población objetivo.

Si obtenemos el promedio de estos valores, veremos que el promedio es $4946/30=164,8667$ cm.

Nunca debemos olvidar de agregar la unidad en que se mide lo que queremos expresar.

Hay excepciones, que se producen cuando las observaciones no tienen unidad, como, por ejemplo, cocientes entre alto y ancho de algún objeto.

En todos los demás casos, **debe estar la unidad de medida.**

Recordemos que el promedio es una medida de **centro** o de **tendencia central**. Es como un **representante** de la población.

Supongamos que obtenemos una muestra de 10 alumnos, seleccionados totalmente al azar, sin reposición, y resultó ser la siguiente:

| | | | | | | | | | | |
|-----------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| Muestra 1 | 147 | 163 | 184 | 143 | 172 | 177 | 151 | 169 | 181 | 164 |
|-----------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|

El promedio de la muestra es 165,1 mts. Se puede ver que es parecido (pero no igual) al promedio de toda la población, 164,8667 cm.

Ahora obtendremos tres muestras aleatorias más. La muestra 2, sin reposición.

Las muestras 3 y 4 son con reposición. En la 3, se repitió el 169, en la 4 se repitió el 178.

| | | | | | | | | | | |
|----------|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| muestra2 | 176 | 178 | 175 | 170 | 185 | 147 | 149 | 171 | 169 | 153 |
| muestra3 | 146 | 170 | 169 | 182 | 185 | 185 | 166 | 156 | 169 | 163 |
| muestra4 | 163 | 178 | 161 | 176 | 178 | 184 | 151 | 161 | 181 | 182 |

Los promedios de las muestras 2, 3 y 4 son, respectivamente, 167,3; 169,1 y 171,5 cm. Todos parecidos al verdadero promedio de la población, 165,8667 cm.

Una pregunta sobre la cual podemos reflexionar es: ¿son suficientemente cercanos los promedios de las muestras al promedio de la población objetivo?

ACTIVIDAD PRÁCTICA

Haz una lista de las alturas de todos los alumnos del curso.

Calcula el promedio.

Corta un papel en cuadritos, escribe la altura en cada uno, dóblalos y ponlos en una caja o bolsa.

Fija un tamaño de muestra, por ejemplo, 7, y obtén una muestra al azar, sacando papelitos de la bolsa. Calcula el promedio de las alturas de la muestra y compáralo con el promedio de la población.



Repite lo anterior varias veces, con y sin reposición.

ACTIVIDAD COMPUTACIONAL EXCEL

Usando el sistema Excel, ingresa los valores de las alturas de todos tus compañeros incluyendo la tuya. Esta es tu población.

Calcula el promedio de las alturas usando la función.

Obtén muestras aleatorias de distintos tamaños, con y sin reposición. Para esto deberás ir a **Datos** y abrir el menú **Análisis de datos**.

Elige **muestra**. Aparecerá un menú en que deberás ingresar el rango de los datos que ingresaste, el número de muestras (el tamaño de la muestra) y el rango donde quieres que esté la muestra. Repite lo anterior varias veces.

En cada caso calcula el promedio y compárelo con la altura promedio poblacional.

La muestra es con reposición.

6. La variación

Nada es constante.

MOTIVACIÓN

Si compramos cerámica y pasado un tiempo nos falta y compramos más, de la misma marca y tipo, es muy posible que nos toque de otra partida de producción, y el color sea ligeramente distinto.

Todos los fenómenos que observamos tienen una propiedad común: tienen variación; es decir, si el fenómeno se repite, sus características serán ligeramente diferentes.

Esta variación se debe a **múltiples factores** que influyen en **pequeña medida**, como cambios en la temperatura, corrientes de aire, estados de ánimo de las personas involucradas, entre muchas otras.

Algunos fenómenos tienen variación muy pequeña, como los **experimentos de laboratorio**.

Otros, como los **procesos industriales**, tienen una variación moderada.

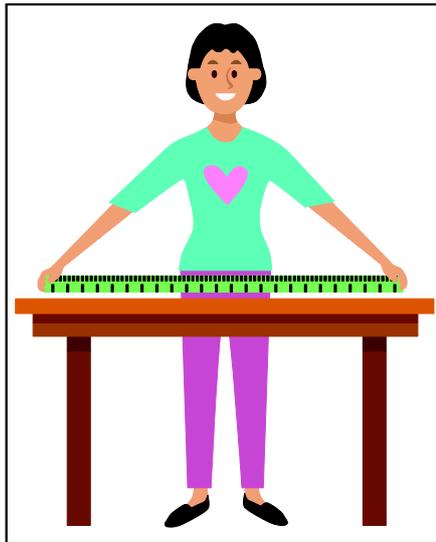
Y hay otros, en los que está muy **involucrado el ser humano**, que tienen mucha variación. Estos son los fenómenos psicológicos, económicos, sociológicos, educacionales, políticos, entre otros.

Si se efectúan varias mediciones sobre un mismo objeto, éstas pueden presentar variación, sobre todo si interviene el ser humano en el proceso de medición.

ACTIVIDAD PRÁCTICA 1

Toma una regla graduada.

Que cada alumno mida el ancho de la mesa del profesor, con precisión de hasta medio milímetro, y lo anote en un papel, sin que los demás sepan el valor que obtuvo.



Al final, hacer la lista de todas las medidas obtenidas.

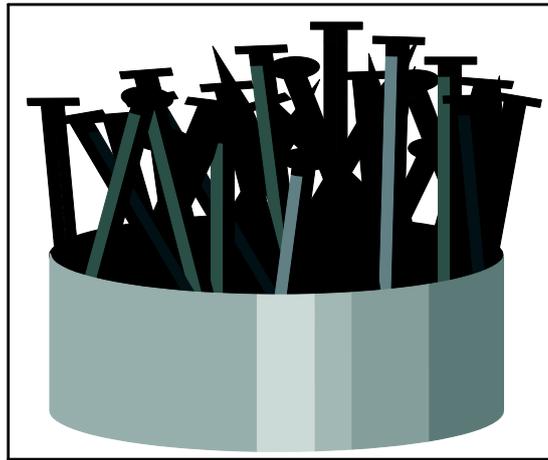
Se puede observar que hay variación entre los valores observados. Aquí la variación es entre las mediciones.

Seguramente muchos valores son parecidos o iguales, mientras que hay unos pocos valores extremos, que se apartan de la mayoría.

ACTIVIDAD PRÁCTICA 2

Toma una cantidad de clavos de una misma medida, por lo menos de 2 pulgadas, digamos que al menos 30 clavos.

Con una regla graduada en milímetros, mide y registra la longitud de cada clavo.



Verás que no todos miden lo mismo, incluso cuando proceden de un mismo paquete.

Con los datos obtenidos, construye un gráfico un histograma. ¿Es apropiado, o sería mejor un gráfico de barras?

Describe lo que observas.

EJERCICIOS

7) Se tiene una población muy pequeña, formada por los números 2, 5, 7, 9, y 12.

a) Extrae todas las muestras posibles de 2 elementos, sin reposición. ¿Cuántas son?

Por cada muestra calcula el promedio y compáralo con el promedio de toda la población. Verás que algunas dan parecido y otras dan muy distinto.

b) Extrae todas las muestras posibles de 2 elementos, con reposición.
¿Cuántas son?

Por cada muestra calcula el promedio y compáralo con el promedio de toda la población. Ahora hay mayor variedad de valores para los promedios de las muestras, algunos muy distintos del promedio de la población.

8) En una industria, una máquina automática de embotellado de jugo en cajas tiene detenciones por cajas que ingresan en mala posición y traban el sistema.

Los siguientes datos corresponden a la cantidad de detenciones de la máquina automática ocurridos durante los primeros 60 días de uso, hasta que se decidió cambiarla.

| Día | Detenciones | Día | Detenciones | Día | Detenciones |
|-----|-------------|-----|-------------|-----|-------------|
| 1 | 8 | 21 | 2 | 4 | 5 |
| 2 | 1 | 22 | 5 | 42 | 1 |
| 3 | 4 | 23 | 8 | 43 | 8 |
| 4 | 0 | 24 | 0 | 44 | 5 |
| 5 | 5 | 25 | 7 | 45 | 2 |
| 6 | 2 | 26 | 0 | 46 | 5 |
| 7 | 4 | 27 | 4 | 47 | 4 |
| 8 | 2 | 28 | 2 | 48 | 3 |
| 9 | 6 | 29 | 5 | 49 | 4 |
| 10 | 2 | 30 | 5 | 50 | 2 |
| 11 | 3 | 31 | 2 | 51 | 2 |

| Día | Detenciones | Día | Detenciones | Día | Detenciones |
|-----|-------------|-----|-------------|-----|-------------|
| 12 | 1 | 32 | 4 | 52 | 0 |
| 13 | 1 | 33 | 5 | 53 | 5 |
| 14 | 3 | 34 | 0 | 54 | 1 |
| 15 | 5 | 35 | 4 | 55 | 3 |
| 16 | 6 | 36 | 3 | 56 | 1 |
| 17 | 1 | 37 | 0 | 57 | 3 |
| 18 | 3 | 38 | 5 | 58 | 4 |
| 19 | 0 | 39 | 6 | 59 | 1 |
| 20 | 8 | 40 | 3 | 60 | 5 |

Asumamos que esta es nuestra población. En promedio son 3 detenciones diarias.

Obtén una muestra aleatoria.

Antes deberás decidir el tamaño de la muestra, y si va ser con o sin reposición.

También deberás decidir el método para asegurarte que la muestra sea tomada al azar. Por ejemplo, enumera papелitos con los números del 1 al 60 y extrae papeles en forma aleatoria.

Calcula el promedio del número de detenciones en la muestra y compáralo con el valor de la población.

Una advertencia: está comprobado que las personas no funcionan bien como generadores de procesos aleatorios.

Si tú tomas la decisión sobre cuáles estarán en la muestra, éste resulta no ser un buen método de selección de una muestra al azar.



7. Gráficos de barra e histogramas

Un gráfico dice más que mil palabras.

MOTIVACIÓN

Una imagen dice más que mil palabras. Este es un dicho que seguramente conoces. Pero es muy cierto.

Por eso la Estadística ha entendido que los gráficos son importantes para resumir y transmitir información.

Siempre que estén bien hechos, **no distorsionen** la información, y sean **autocontenidos**.

Esto último significa que debieran explicarse por sí solos, sin necesidad de tener que buscar en el texto cómo interpretar o qué se pretende mostrar con el gráfico.

En esta sección explicaremos lo relacionado con dos gráficos muy utilizados, que se parecen, pero no son iguales: el **gráfico de barras** y el **histograma**.

Primero consideraremos datos de tipo **categoricos**, o sea, **no numéricos**.

Hay básicamente dos formas de **presentar** estos datos.

Una es como una lista en que cada uno aparece como una observación individual, con los valores de la categoría a que pertenece.

Estos pueden estar en algún orden determinado, o simplemente desordenados.

A esta manera de presentar los datos se le suele referir como **datos a granel**.

Una segunda forma de presentar un conjunto de datos categoricos, de tal modo que sea más entendible, es mediante una **tabla de frecuencias**.

Esta tabla tiene, en su forma más simple, dos columnas, en una están las **categorías** y en la otra están las **frecuencias**, que son las veces que aparece cada categoría.

Si los datos están **a granel**, lo recomendable es **tabularlos**, o sea, construir una **tabla de frecuencias** a partir de ellos.

Para ello se clasifica cada dato en la categoría que le corresponde, y se lleva la cuenta. La frecuencia de una categoría es el número de datos que tienen esa categoría.

Con eso no estamos resumiendo la información, sino que estamos presentando los datos de una forma más fácil de entender.

El paso siguiente es representar las frecuencias en un **gráfico de barras**, que, como lo dice su nombre, consiste en barras, verticales u horizontales, cuyas longitudes son proporcionales a las frecuencias.

Veamos estas cosas en el siguiente Ejemplo con datos categóricos.

EJEMPLO 12

Egresados de un instituto profesional.

Supongamos que en el año 2019 egresaron 982 personas del Instituto Profesional Aurora, en las especialidades de Administración, Literatura, Educación, Biología y Ciencias Sociales.



De los 982 egresados, 512 son hombres y 470 son mujeres.

La lista completa, en orden alfabético de apellidos, podría tener una forma como la siguiente (seguramente incluiría otros datos adicionales)

| Número de orden | Nombre | Apellido | Especialidad |
|-----------------|-----------|----------|-------------------|
| 1 | Patricio | Abarzúa | Literatura |
| 2 | Constanza | Alvarez | Biología |
| 3 | Catalina | Ascui | Educación |
| ... | ... | ... | ... |
| 981 | Benjamín | Zamora | Administración |
| 982 | Javier | Zárate | Ciencias Sociales |

A partir de esta lista, contando cuántos casos hay por cada especialidad, y por sexo, podemos elaborar una **tabla de doble entrada**, que muestra el número de Hombres, de Mujeres y los totales egresados, en cada Especialidad.

Es la siguiente:

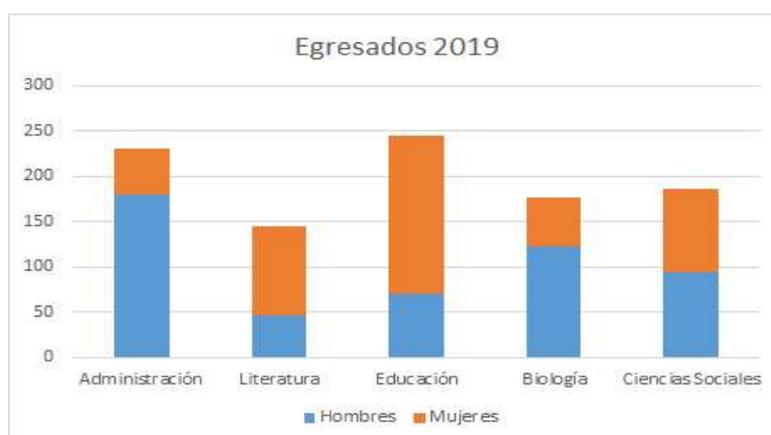
| Especialidad | Hombres | Mujeres | Total |
|-------------------|---------|---------|-------|
| Administración | 180 | 50 | 230 |
| Literatura | 46 | 98 | 144 |
| Educación | 70 | 175 | 245 |
| Biología | 122 | 55 | 177 |
| Ciencias Sociales | 94 | 92 | 186 |
| Total | 512 | 470 | 982 |

En esta tabla se ha **resumido información**, pues no aparecen individualizadas las personas, pero entrega un panorama mucho **más claro** de cómo se distribuyen los egresados según especialidad y sexo.

El siguiente paso, para presentar estos datos con mayor claridad, es construir un **gráfico de barras**. Para ello usaremos Excel.

Para distinguir entre el número de Hombres y de Mujeres, las barras las dividiremos en dos trozos de colores diferentes, siendo la longitud del trozo de abajo proporcional a la frecuencia de los Hombres, la longitud del trozo de arriba proporcional a la frecuencia de las Mujeres, por cada una de las especialidades.

El resultado es el siguiente:



Observa que el orden en que se ponen las barras es arbitrario. Se podría haber puesto Ciencias Sociales primero, sin que esto nos ocasione problemas.

Esto es porque representan categorías, sin orden.

Ahora vamos a ver otro ejemplo, con datos numéricos en lugar de categorías.

EJEMPLO 13

Puntajes en un examen de postulación a un trabajo.

Los datos que se presentan a continuación son los puntajes obtenidos en un examen por un grupo de 25 postulantes a un trabajo (en escala de 1 a 20 puntos).

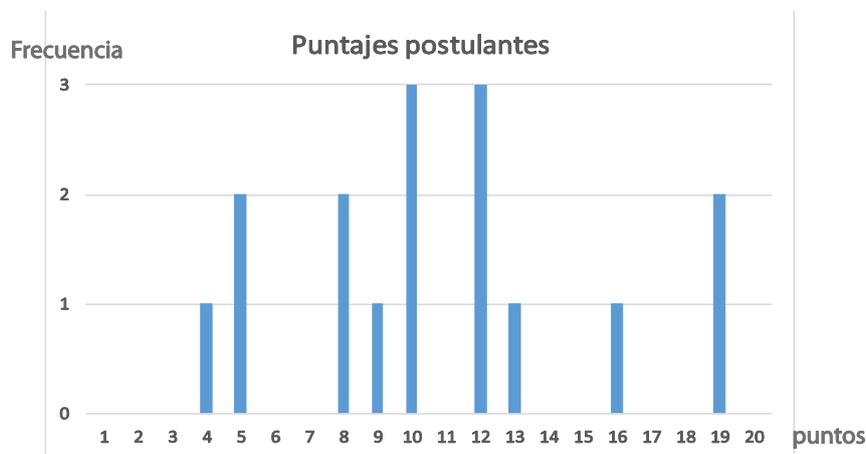


| | | | | |
|----|----|----|----|----|
| 10 | 4 | 5 | 10 | 15 |
| 12 | 19 | 13 | 16 | 6 |
| 8 | 5 | 12 | 11 | 15 |
| 19 | 8 | 12 | 11 | 7 |
| 16 | 10 | 9 | 13 | 13 |

Son **datos a granel**. Los vamos a convertir en una tabla de frecuencias:

| | | | | | | | | | | | | | | | | |
|-------------|---|---|---|---|---|---|----|----|----|----|----|----|----|----|----|----|
| Puntajes | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 | 19 |
| Frecuencias | 1 | 2 | 1 | 1 | 2 | 1 | 3 | 2 | 3 | 3 | 0 | 2 | 2 | 0 | 0 | 2 |

Vamos a representar estos datos en un gráfico de barras, nuevamente utilizando Excel.



Observa que las barras están ordenadas de acuerdo al valor numérico que representan.

En el Ejemplo anterior, no representan números, y no tienen definido un orden.

En este caso son números. Sería poco afortunado alterar el orden natural de los números.

Ahora explicaremos qué es un **histograma**, sus similitudes y sus diferencias con un gráfico de barras.

En primer lugar, se debe construir una **tabla de frecuencias por intervalos**.

Se definen intervalos, y se cuenta el número de los datos que caen en cada uno de esos intervalos.

A continuación, describiremos el procedimiento para construir los intervalos. Parece complicado, pero en realidad es bien simple.

Para construir los **intervalos**, primero se debe decidir **cuántos** intervalos queremos.

Si hay **muchos** intervalos, se resumirá poco la información y el resultado será **poco entendible**.

Si hay muy **pocos** intervalos, se resume demasiado, perdiéndose mucha de la información.

Como ya hemos dicho antes, hay que buscar un punto intermedio entre **resumir** y **no perder demasiada información**.

Una receta simple, si tenemos n datos, es extraer la raíz cuadrada de n y aproximarla al entero.

Ese puede ser un punto de partida para tomar la decisión sobre el número de datos, aumentándolo o disminuyéndolo según lo que uno estime conveniente.

De esa forma, como una pauta, si hay 30 observaciones, pensar entre 5 o 6 intervalos; con 50 observaciones, 7 intervalos; 80 observaciones, 8 o 9 intervalos; 150 observaciones, 12 o 13 intervalos; 200 observaciones, 14 o 15 intervalos, etc. Pero esto es sólo una pauta.

Para definir los intervalos, considerar la menor y la mayor de las observaciones.

Si la **diferencia** entre ambos valores es D y el **número de intervalos** es k , el ancho de cada intervalo es D/k . Esto se aproxima para que sea un número *redondo*.

Se elige un punto de partida de modo que no sea mayor que el menor de los datos, para que éste no quede fuera de los intervalos.

Hay que tener cuidado de que el mayor de los datos no sea mayor que el límite superior del último de los intervalos.

Si esto pasa, se debe aumentar el ancho de los intervalos o bien aumentar el número intervalos. No pueden quedar datos fuera de los intervalos.

Una vez definidos los intervalos, se procede a **clasificar** cada dato en el intervalo que lo contiene, y llevar la cuenta.

Antes, hay que decidir qué hacer si una observación **coincide con el límite** entre dos intervalos: si se incluirá en el intervalo inferior o en el intervalo superior.

Esa decisión es arbitraria, pero una vez tomada, debe aplicarse a todos los datos por igual.

Terminada la **tabla de frecuencias por intervalos**, procedemos a construir el histograma:

El histograma consta de un eje horizontal que representa los números reales.

En este eje se trazan marcas que corresponden a los límites de los intervalos previamente definidos.

Se dibujan rectángulos, cuyas bases son los intervalos, y cuyas alturas son proporcionales a las frecuencias.

De este modo, los rectángulos correspondientes a intervalos seguidos quedan pegados uno al lado del otro.

En el gráfico de barras, éstas están separadas.

EJEMPLO 14

Venta de bebidas en un minimarket.

El dueño de un minimarket quiere conocer cómo son sus ventas semanales de bebidas.

Para eso registró las ventas durante 30 semanas seleccionadas al azar, de entre los dos últimos años.



Los datos que obtuvo son los siguientes, en miles de pesos:

| | | | | | |
|-------|------|-------|-------|-------|-------|
| 93,4 | 68,3 | 32,4 | 104,8 | 104,4 | 92,0 |
| 82,8 | 76,5 | 112,2 | 85,7 | 115,2 | 106,4 |
| 80,6 | 79,8 | 89,6 | 98,0 | 37,9 | 52,1 |
| 93,2 | 62,2 | 66,1 | 65,2 | 42,1 | 88,4 |
| 110,0 | 78,5 | 59,7 | 117,1 | 109,5 | 59,2 |

Haremos una **tabla de frecuencias por intervalos** con estos datos.

Son 30 datos, por lo tanto 5 puede ser un buen número de intervalos.

El valor menor es 32,4 y el mayor es 117,1 mil pesos, la diferencia es 84,7 mil pesos.

$84,7/5=16,94$, podemos redondearlo a 20.

Entonces definiremos cinco intervalos de 20 mil pesos cada uno, partiendo de 20 mil y llegando hasta 120 mil.

Con esto nos aseguramos que todos los valores que aparecen en la tabla estén incluidos en los intervalos.

Antes de contar debemos tomar una decisión: Si algún valor llegara a coincidir con el límite de dos intervalos, ¿en cuál de los dos lo incluiremos?

Esta es una decisión arbitraria que se aplicará en todos los intervalos; en este Ejemplo decidiremos ponerlo en el intervalo superior.

Los intervalos y las frecuencias en cada uno se muestran a continuación.

Se ha incluido una columna para ir contando los valores que están en cada uno de los intervalos, algo que hay que hacer con mucho cuidado para no dejar ningún valor afuera.

| Intervalo | Conteo | Frecuencia |
|-----------|------------|------------|
| 20 a 40 | // | 2 |
| 40 a 60 | //// | 4 |
| 60 a 80 | //////// | 7 |
| 80 a 100 | ////////// | 9 |
| 100 a 120 | //////// | 8 |

Con esta tabla construiremos un histograma.

En el gráfico de barras cada valor es un punto en el eje horizontal.

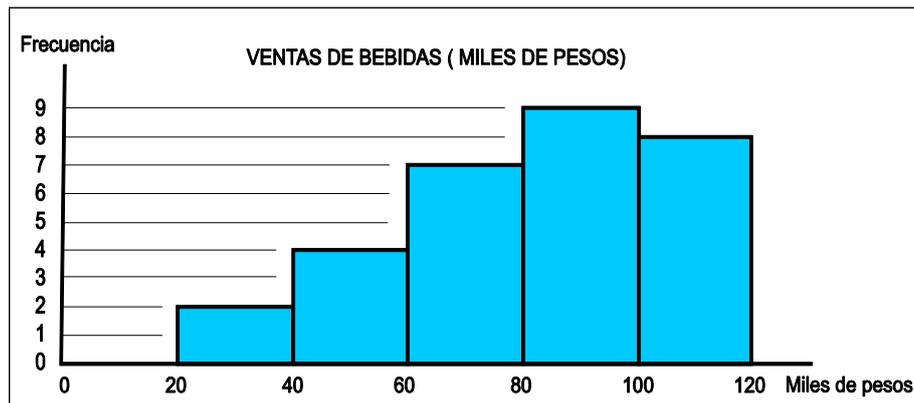
Sólo los valores que aparecen en la muestra están representados, y no hay más.

El histograma es diferente. El eje de horizontal representa un **continuo** de números, los **números reales**. Cada punto del eje representa un número real, un posible valor de la muestra.

Las frecuencias están representadas por rectángulos, cuyos lados coinciden con los límites de los intervalos.

Por lo tanto, los rectángulos correspondientes a intervalo contiguos se representan **pegados** uno al lado del otro.

El histograma se construyó con un programa para dibujar.



Una observación: En un gráfico de barras, las frecuencias son proporcionales a las **longitudes** de las barras.

En un histograma, las frecuencias son proporcionales a las **áreas** de los rectángulos.

Pero como en la gran mayoría de los casos, y **siempre para nosotros**, los intervalos son de **igual longitud**, las bases de los rectángulos son iguales.

En consecuencia, cuando los intervalos son iguales, las alturas de los rectángulos **resultan** proporcionales a las **frecuencias**, como en los gráficos de barras.

Debes tener cuidado, porque en la literatura a veces usan la palabra histograma para referirse a un **gráfico de barras**.

Una **precaución** que debes tener es la siguiente:

A veces en la literatura se presentan gráficos muy hermosos y llamativos, que suelen llamar **infogramas**.

Hay que tener cuidado, porque estos tienden a distorsionar la información, o a ser poco claros en lo que quieren transmitir.

Esto puede ser aceptable en algunos contextos **informales**.

Pero si se quiere ser **precisos** en la información que se desea transmitir, debemos preferir los **gráficos estadísticos**.

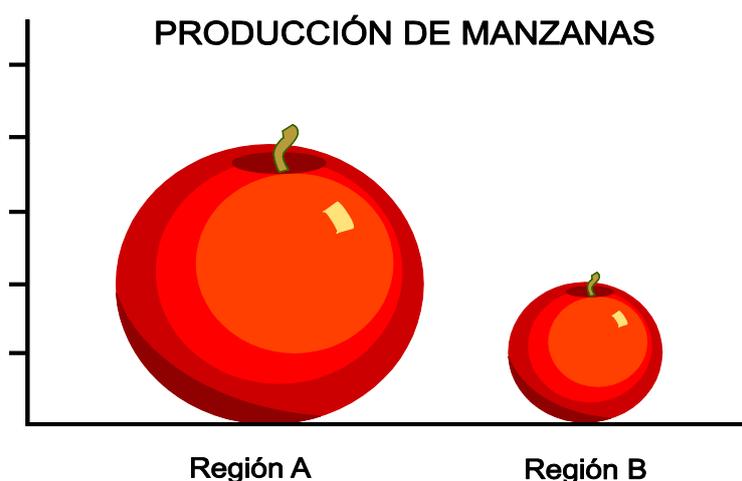
Vamos a dar un ejemplo:

EJEMPLO 15

Producción de manzanas.

En un informe sobre la producción de manzanas, se pretendió mostrar un gráfico que permitiera comparar la producción de esta fruta de la Región A con la de la Región B.

Con el objeto de atraer la atención del lector, en lugar de un gráfico de barras se elaboró un bonito infograma, como el que se muestra a continuación:



Muy atractivo, pero no queda claro si las producciones son proporcionales a la **altura** de las manzanas, al **área visible** de las manzanas, o al **volumen** de ellas.

Seguramente sabes que el área de un círculo de diámetro d está dada por $\pi d^2/4$ y el volumen de una esfera por $\pi d^3/6$ (las manzanas se dibujaron con forma de esfera).

π es el número de veces que cabe el diámetro de un círculo en su circunferencia, y es un número irracional aproximado a 3,1416 (tiene infinitos decimales).

El gráfico muestra que el diámetro de la manzana grande es el doble de la correspondiente a la manzana pequeña.

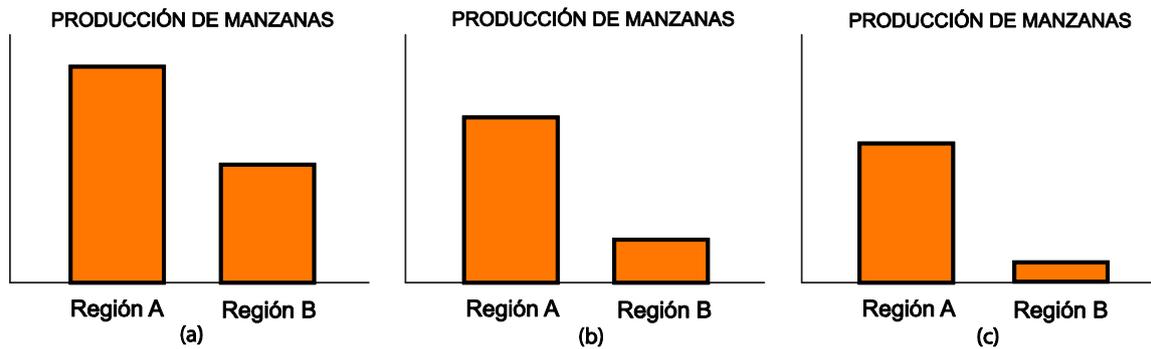
Tomemos el diámetro de la manzana grande como 1 y el de la pequeña como 0,5.

Las alturas, las áreas y los volúmenes por cada Región están dadas en la siguiente tabla.

La tabla también contiene la producción de la Región B como porcentaje de la producción en la Región A.

| Interpretación | Región A | Región B | Porcentaje de B respecto de A |
|----------------|----------|--------------|-------------------------------|
| Altura | 1 | 0,5 | 50 % |
| Área | $\pi/4$ | $0,25\pi/4$ | 25 % |
| Volumen | $\pi/6$ | $0,125\pi/6$ | 12,5 % |

Las tres interpretaciones posibles del **infograma** se muestran en los siguientes gráficos de barras:



¿Qué tal? Confuso el infograma, ¿no es cierto?

EJERCICIOS

9) Con los datos de las detenciones de la envasadora de jugo, del Ejercicio 8, construye un gráfico de barras.

10) Los siguientes datos corresponden a los valores de precipitación de azúcar medido en la sangre de 63 individuos:

| | | | | | | | | |
|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| 91 | 46 | 112 | 87 | 92 | 108 | 94 | 132 | 83 |
| 115 | 71 | 97 | 87 | 78 | 96 | 112 | 123 | 125 |
| 112 | 82 | 33 | 95 | 111 | 102 | 87 | 101 | 132 |
| 108 | 113 | 58 | 91 | 103 | 95 | 126 | 112 | 67 |
| 108 | 88 | 78 | 113 | 94 | 95 | 125 | 134 | 89 |
| 95 | 100 | 90 | 101 | 53 | 102 | 85 | 132 | 97 |
| 136 | 98 | 87 | 77 | 115 | 65 | 88 | 90 | 94 |

a) Construye una tabla de frecuencias por intervalos. Debes decidir cuántos intervalos y de qué largo.

b) A partir de la tabla, construye un histograma. ¿Observando el histograma, qué puedes decir?

8. Medidas de centro: la media y la mediana.

Todo gira en torno al centro.

Hay medidas que se **calculan** a partir de datos numéricos, y que sirven para **resumir** esos datos.

Son medidas que **resumen** la información contenida en los datos.

Se espera que estas medidas **describan** alguna característica del conjunto de datos.

Unas medidas que describen un conjunto de datos, que seguramente ya conoces, son las **medidas de centro**.

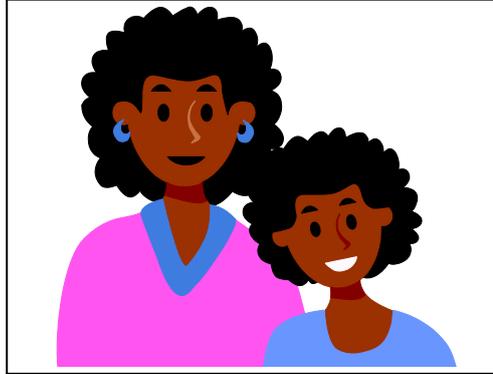
Estas indican lo que se puede considerar como el **centro** de un conjunto de datos.

Hay más de una medida de centro, y las vamos a repasar a continuación.

La **media** o **promedio** es la suma de los valores dividido por el número de datos.

Entonces ocurre que no necesariamente el promedio se expresa en la misma escala que las observaciones originales.

Según el Instituto Nacional de Estadísticas, en 2017 el número promedio de hijos por cada mujer era de 1,6. Ninguna mujer tiene 1,6 hijos, pero como promedio es aceptable que no sea entero.



EJEMPLO 16

Notas de Ciencias Sociales (promedio).

Supongamos que el profesor de Ciencias Sociales toma una prueba a un curso de 25 estudiantes.

El profesor corrige la prueba y registra las notas.



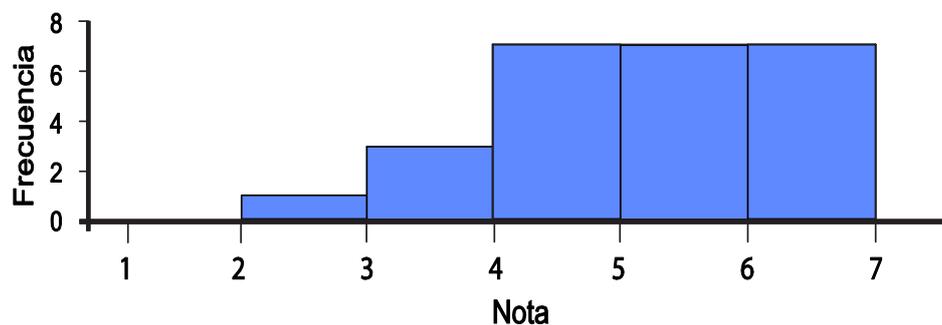
Él quiere resumir los resultados, para tener una idea de cómo respondió el curso al aprendizaje de la materia que se evaluó en la prueba.

Una buena medida para resumir es obtener el promedio de las notas del curso.

Supongamos que las siguientes son las notas obtenidas por sus alumnos, ordenadas según el orden alfabético de los apellidos, que acompañamos por un histograma:

| | | | | |
|-----|-----|-----|-----|-----|
| 5,2 | 4,6 | 6,2 | 5,9 | 7,0 |
| 4,9 | 5,8 | 3,2 | 6,1 | 5,8 |
| 6,5 | 4,9 | 2,4 | 6,0 | 4,8 |
| 3,2 | 4,8 | 5,9 | 6,2 | 4,7 |
| 6,8 | 3,2 | 5,3 | 4,2 | 6,5 |

Prueba de Ciencias Sociales

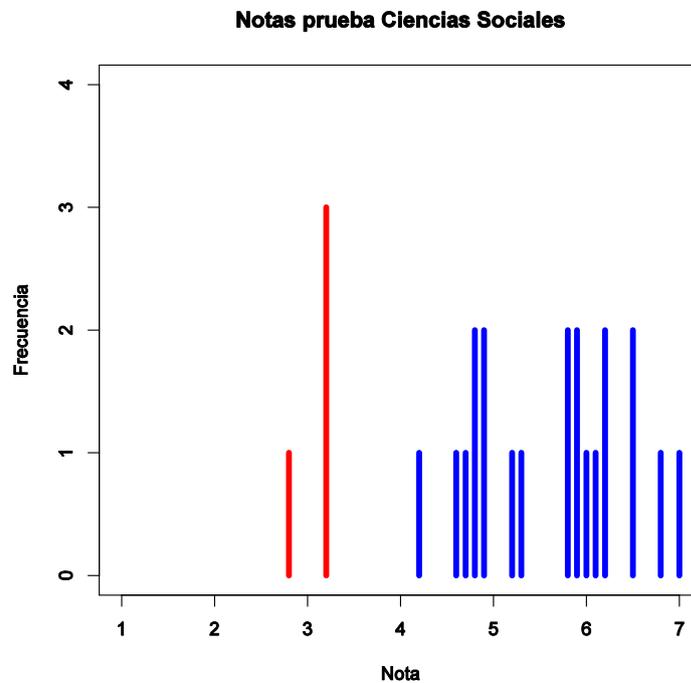


Puedes verificar que las notas suman 130,1 y si la dividimos por el total de alumnos, 25, obtenemos el promedio 5,204

Observa que las notas tienen una décima, pero el promedio está expresado con décimas y centésimas.

Se puede interpretar como que el **centro** de los datos es 5,204. O bien como si todo el curso completo obtuvo un 5,204.

El siguiente gráfico de barras ilustra el conjunto de las notas (en rojo las que están bajo 4,0).



Pero hay otras medidas de centro.

Una es la **mediana**. Es un número tal que al menos el 50% de los datos es menor o igual que él, y al menos el 50% de los datos es mayor o igual a él.

Es complicada la definición, pero en la práctica se obtiene de la siguiente manera, muy sencilla:

Se ordenan de menor a mayor.

Si hay un número impar de datos, la mediana es el que quedó al centro.

Si hay un número par de datos, es el promedio de los dos que quedaron al centro.

EJEMPLO 17

Notas de Ciencias Sociales (mediana).

Continuación del Ejemplo 16, de las notas de la prueba de Ciencias Sociales. Calcularemos la mediana.

Primero viene la parte más difícil, ordenar las notas de menor a mayor.

Quedan así:

| | | | | |
|-----|-----|-----|-----|-----|
| 2,4 | 3,2 | 3,2 | 3,2 | 4,2 |
| 4,6 | 4,7 | 4,8 | 4,8 | 4,9 |
| 4,9 | 5,2 | 5,3 | 5,8 | 5,8 |
| 5,9 | 5,9 | 6,0 | 6,1 | 6,2 |
| 6,2 | 6,5 | 6,5 | 6,8 | 7,0 |

Hay 25, luego la mediana es la nota del centro, la del lugar 13, que corresponde a un 5,3.

Podemos observar que es parecido al promedio, 5,22 pero no igual.

Es simplemente otra medida de centro.

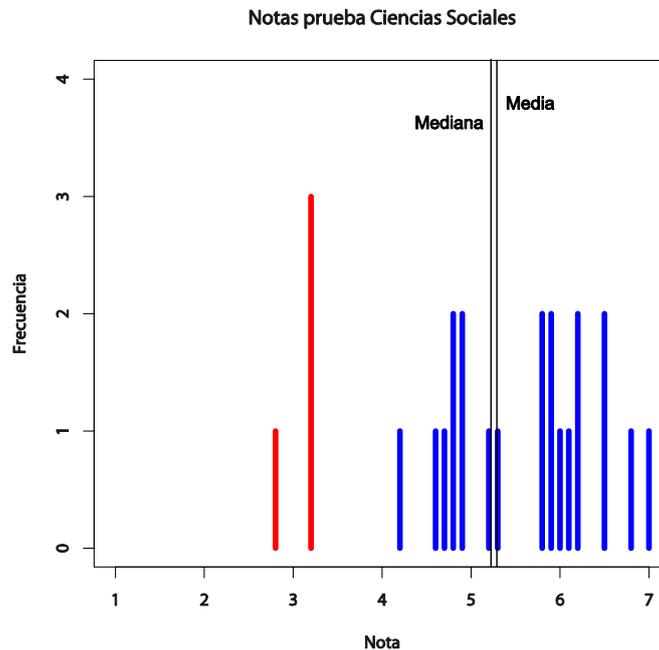
La figura siguiente muestra un gráfico de barras de las notas, con las medidas de centro.

Antes de hacer el gráfico, una observación:

Siempre que hagamos cualquier tipo de gráfico, no debemos olvidar de ponerle un título descriptivo y de ponerle títulos a los ejes.

Además, si corresponde, agregar la unidad de medida de las variables representadas en los ejes.

Un gráfico debe entenderse por si solo. Si no, simplemente no sirve.



Hemos marcado la ubicación del promedio y de la mediana, para ver que son ambas medidas de centro, aunque difieren un poco entre ellas.

¿Cuál es la diferencia entre la **media** y la **mediana**?

La media es más fácil de calcular.

Intenta sumar estos 20 números, sin usar calculadora, y tómate el tiempo:

3, 1, 10, 12, 2, 8, 14, 4, 10, 5, 1, 14, 12, 8, 7, 4, 4, 9, 11, 15.

Ahora ordénalos de menor a mayor, y tómate el tiempo.

Con toda seguridad te demoraste más en ordenarlos que en sumarlos.

Otra diferencia muy importante entre la media y la mediana:

La media es muy **sensible** a **valores extremos**, mientras que la mediana es poco sensible.

Cuando los datos presentan **asimetría**, es decir, contienen valores muy alejados del centro, o muy grandes o muy pequeños, es mejor usar la mediana, como medida de centro, pues la media aparece distorsionada por los valores extremos.

Otra medida de centro, aunque no muy buena, es la moda.

Consiste en el valor que más se repite.

En el ejemplo de las notas la moda es el 3,2. Te darás cuenta que no está muy al centro.

En general, la moda sirve como medida de centro cuando hay una cantidad muy grande de datos.

Hay conjuntos de datos que tienen más de una moda.

9. Medidas de posición: los Percentiles.

El centro y otros lugares.

Se puede generalizar la idea de la mediana y definir otras medidas que no corresponden a un centro, sino que a otras posiciones dentro del conjunto de datos. Son **medidas de posición**.

Estas medidas son los percentiles, que dividen el conjunto de datos en dos grupos con determinados porcentajes de observaciones.

Primero daremos una definición y luego presentaremos un método para encontrar un percentil.

Sea q un número entero entre 1 y 99. El **percentil**, que designaremos P_q , es un número tal que al menos $q\%$ de los datos son menores o iguales a él, y al menos $(100-q)\%$ de los datos son mayores o iguales a él.

La mediana, entonces, es un caso especial de percentil. Es el percentil 50, puesto que el 50% de los datos son menores o iguales a ella y el 50% de los datos son mayores o iguales.

Como en el caso de la mediana, la definición anterior es un tanto difícil de entender, pero hay una forma simple de obtener los percentiles, que es la siguiente:

Se quiere el percentil q , con q un entero entre 1 y 99.

Primero hay que ordenar los datos de menor a mayor (esa es la parte más complicada).

Después se debe calcular $R=q \times n/100$

Si R es entero, el percentil q es el promedio de la observación que ocupa el lugar R y la que ocupa el lugar $R+1$ en el conjunto ordenado.

Si R no es entero, se debe aproximar al entero superior. Sea E ese entero. El percentil q es la observación que ocupa la posición E en el conjunto ordenado de datos.

EJEMPLO 18

Notas de Ciencias Sociales (percentiles).

Continuaremos con el Ejemplo 17 de las notas de Ciencias Sociales.

Ahora supongamos que el profesor de Ciencias Sociales desea saber cuáles son los percentiles 25 y 75.



Las notas ya las tenemos ordenadas en el Ejemplo 17. Recordemos que son 25 notas.

Primero veamos el percentil 25:

Aquí $R=25 \times 25 / 100 = 6,25$

No es entero, luego lo aproximamos al entero superior $E=7$.

El percentil 25 es la nota que ocupa el 7o lugar, es decir, 4,7.

Significa que al menos el 25% de las notas

son iguales o inferiores a 4,7 y al menos el 75% de las notas son iguales o superiores a 4,7.

Efectivamente, si contamos, vemos que 7 notas son menores o iguales a 4,7, eso representa el $100 \times 7 / 25 = 28\%$ de las observaciones.

Y podemos ver que 19 notas son mayores o iguales a 4,7.

Esto representa un $100 \times 19 / 25 = 76\%$ de las observaciones.

El 4,7 cumple con la definición de percentil 25.

Ahora el percentil 75:

$$R = 75 \times 25 / 100 = 18,75$$

Nuevamente tenemos un resultado no entero, luego aproximamos $\$R$ al entero superior, y obtenemos $E=19$.

El percentil 75 es la nota que ocupa el lugar 19, vale decir, el 6,1.

Entonces, el 75% de las notas son menores o iguales a 6,1 y el 25% son mayores o iguales a 6,1.

Veamos si efectivamente es el percentil 75.

Resulta que 19 notas son menores o iguales a 6,1, eso representa el $100 \times 19 / 25 = 76\%$ de las observaciones.

Y 6 notas son mayores o iguales a 6,1, lo que representa un $100 \times 6 / 25 = 24\%$ de las observaciones.

El 6,1 cumple con la definición de percentil 75.

Ahora podríamos calcular el percentil 50, que debería ser igual a la mediana.

$$R=50 \times 25/100=12,5$$

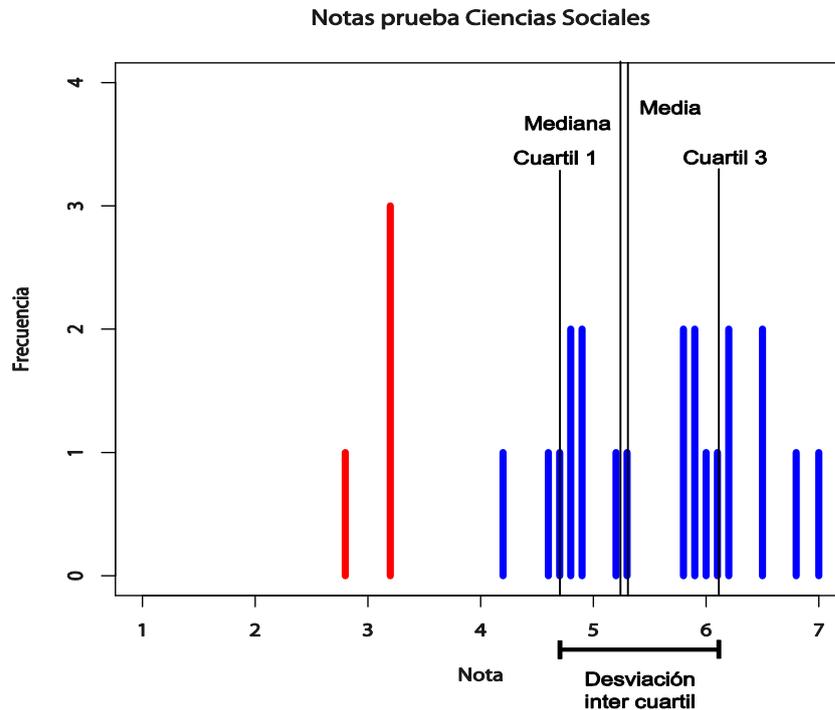
Se debe aproximar al entero superior. Nos da 13.

Busquemos la nota que está en el lugar 13 del conjunto ordenado, y corresponde a la mediana 5,3 que ya habíamos calculado en el Ejemplo 17.

La figura siguiente muestra el mismo gráfico de barra que el Ejemplo 17, pero se han agregado dos líneas que muestran la posición de los percentiles 25 y 75, también llamados **cuartil 1** y **cuartil 3**, respectivamente, porque dividen el conjunto de datos en cuatro.

La mediana es también el **cuartil 2**.

La distancia entre los dos cuartiles se denomina **desviación intercuartil**, y está representada en el gráfico siguiente. Es una medida de cuán dispersos están los datos.



Dijimos que los

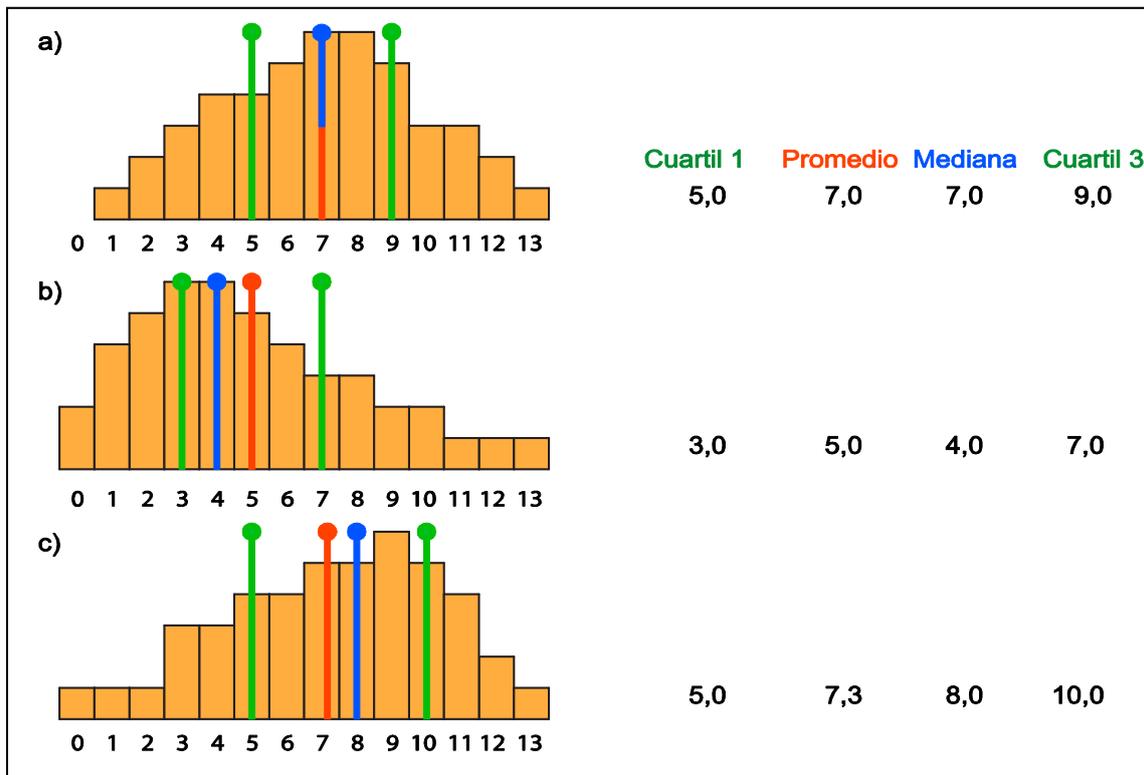
percentiles 25, 50 y 75, también se llaman **cuartiles**. Se simbolizan por Q_1 , Q_2 y Q_3 .

De forma similar, si consideramos los percentiles 20, 40, 60 y 80, también se denominan **quintiles**, porque dividen el conjunto de datos en cinco grupos, con un 20% en cada uno. Son los quintiles 1, 2, 3 y 4.

Los otros que tienen un nombre particular son los percentiles 10, 20, 30, 40, 50, 60, 70, 80, y 90, que dividen el conjunto de datos en 10 grupos con un 10% en cada grupo.

Obviamente, estos se llaman **deciles**. Son los deciles 1 a 10.

La figura siguiente muestra tres histogramas que corresponden a tres situaciones hipotéticas.



En el caso a) se observa que hay bastante **simetría**. Como consecuencia, el promedio (en rojo) y la mediana coinciden (en azul). Los cuartiles (en verde) están a ambos lados de la mediana, y a la misma distancia.

En el caso b) hay **asimetría**, con una cola hacia la derecha. Eso causa que el promedio quede a la derecha de la mediana. Recuerda que el promedio está afectado por observaciones extremas, los valores de la cola en este caso, mientras que la mediana no.

Esos valores extremos son causa de que el cuartil 3 se aleje más hacia la derecha de la mediana, mientras que el cuartil 1 está más cerca de ésta, a la izquierda.

En el caso c) se da lo contrario: hay asimetría, pero con una cola hacia la izquierda. Eso causa que el promedio quede a la izquierda de la mediana, el lado donde están los valores extremos.

Esos valores extremos hacen que el cuartil 1 se aleje más hacia la izquierda de la mediana, mientras que el cuartil 3 está más cerca de la mediana, a la derecha.

Algunas observaciones:

Recordemos que dijimos que la **mediana** es una medida de centro **robusta**.

Eso significa que, a diferencia de la media, está muy poco afectada por observaciones extremas.

Pues bien, los **percentiles** son todos **medidas de posición robustas**. Las observaciones extremas los afectan muy poco.

Otra observación: es posible que haya más de un número que cumple con la definición que dimos de **percentil**.

Por eso hay más de un método de cálculo de percentiles. Pero todos llegan a valores muy parecidos.

Tercera observación: en jerga popular suelen referirse a los quintiles como cada **grupo** de 20% de datos contenido entre dos quintiles contiguos.

Eso es un error: los quintiles son los **números que dividen** el conjunto de datos en grupos de 20% en cada uno, y no el grupo mismo.

EJERCICIOS

11) Con los datos de las detenciones de la máquina envasadora de jugo, del Ejercicio 8, obtén la media, la mediana y los quintiles.

No te olvides de las unidades de medida.

12) Con los datos del Ejercicio 10, de la precipitación de azúcar en la sangre, obtén la media, la mediana y los cuartiles.

10. El diagrama de cajón con bigotes

Una alternativa a los histogramas.

También llamado diagrama de **cajón** o de **caja**, o bien **cajagrama**.

Es un gráfico construido en base de **medidas robustas**.



Por eso tiene la ventaja de estar poco influenciado por datos extremos.

Es más, nos permite visualizar con claridad cuáles datos son efectivamente extremos, si los hay.

Para construir un gráfico de cajón se traza una línea auxiliar con una escala numérica. Lo normal es que sea horizontal, pero también puede ser vertical.

Luego se dibuja un rectángulo, cuyos extremos se posicionan en los cuartiles Q_1 y Q_3 .

Dentro del rectángulo se dibuja una línea posicionada en la mediana.

La distancia $RIC=Q_3-Q_1$ es el **rango intercuartil**.

Medimos la distancia entre el lado izquierdo del rectángulo hasta 1,5 veces el RIC, hacia la izquierda y hacemos una marca.

También medimos la distancia entre el lado derecho del rectángulo hasta $1,5$ veces el RIC hacia la derecha, y hacemos otra marca.

Todos los datos que están entre las dos marcas se llaman **datos interiores** y se considera que no son extremos.

Si hay datos que estén fuera de las dos marcas, hacia la izquierda o hacia la derecha, se consideran **valores extremos**.

Los **bigotes** son trazos que van desde los lados del rectángulo hasta los valores mínimo y máximo, respectivamente, de los datos interiores.

Si hay valores extremos, es recomendable estudiarlos con el objeto de determinar por qué son extremos, si realmente se escapan del grupo de datos, o hay un error, ya sea de observación, de tipeo o de cálculo.

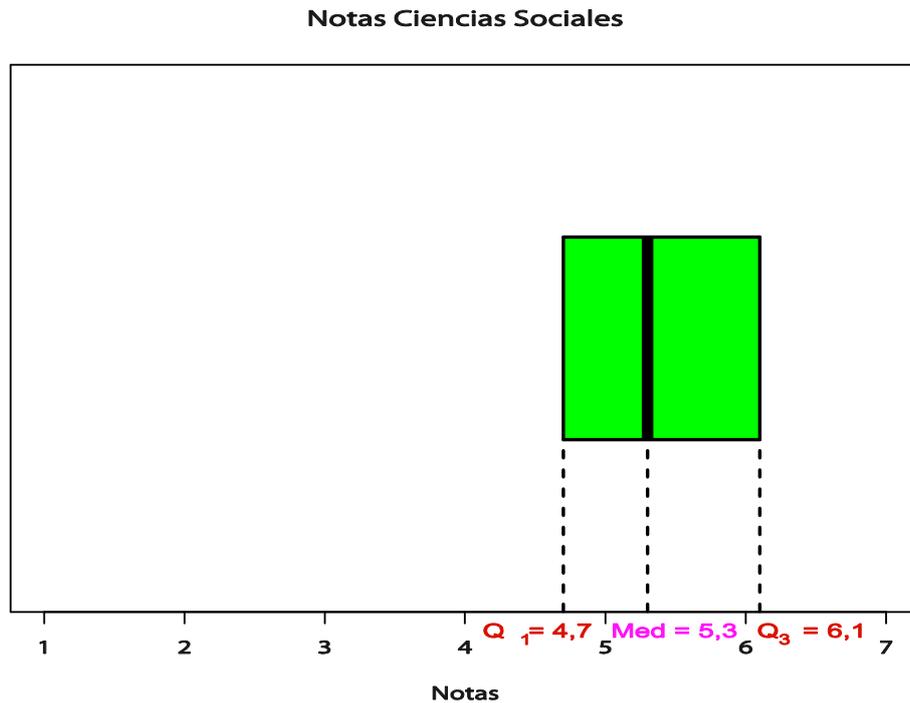
EJEMPLO 19

Notas de Ciencias Sociales (cajón).

Vamos a construir un cajón con bigotes con las notas de la prueba de Ciencias Sociales, del Ejemplo 16.

En los Ejemplos 17 y 18 obtuvimos la mediana y los cuartiles (percentiles 25 y 75), así que gran parte del trabajo está hecho. Vimos que la mediana es $5,3$ y los cuartiles son $4,7$ y $6,1$.

El cajón tiene por lados los cuartiles, y contiene un trazo vertical que representa la mediana. El cajón se está viendo como muestra la figura siguiente:



Ahora tenemos que agregarle los bigotes. El **rango intercuartil** es

$$6,1 - 4,7 = 1,4.$$

Hay que multiplicarlo por 1,5, lo que da 2,1.

Si se le resta 2,1 al cuartil 1 y se le suma 2,1 al cuartil 3, obtenemos 2,6 y 8,2 respectivamente.

La menor de las notas mayores o iguales a 2,8 y la mayor de las notas menores o iguales a 8,2 son los extremos de los **bigotes**.

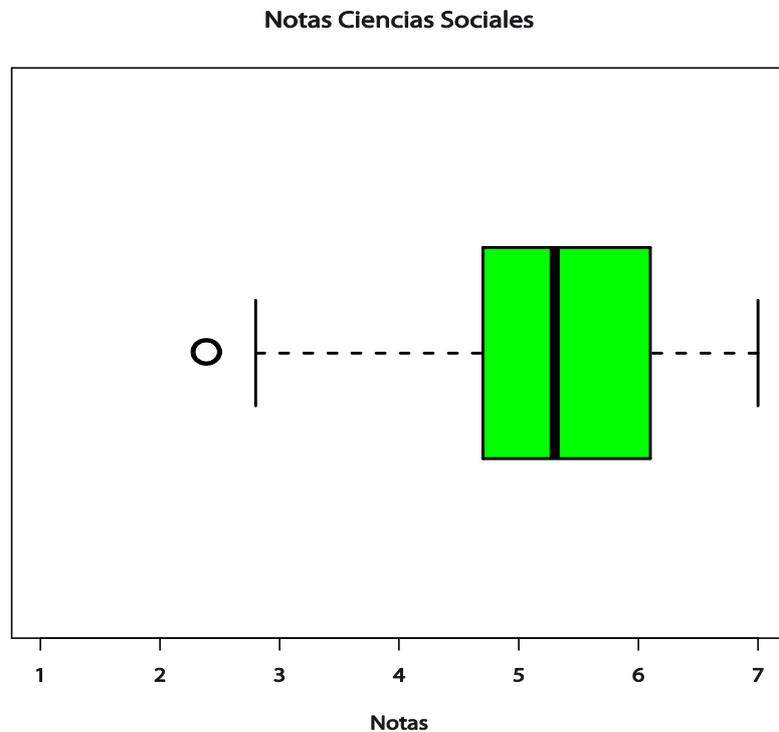
Ellos son, respectivamente, las notas 3,2 y 7,0.

Cualquier nota menor que 2,8 o mayor que 8,2 es considerada una observación extrema.

Es obvio que no hay ninguna mayor que 8,2. Pero sí hay una menos que 2,6, el 2,4 que obtuvo un alumno desafortunado.

Tales datos se suelen representar por círculos o asteriscos.

El siguiente es el cajón con bigotes terminado, al que no hemos olvidado ponerle título:



Ahora veremos otro uso de las medidas de centro. Se trata de evaluar la **asimetría** que pueden presentar los datos.

La asimetría se forma por la presencia de datos extremos, hacia uno de los lados, ya sea que sean más grandes que la mayoría de los datos restantes, o ya sea que son más pequeños que la mayoría de los datos.

Dijimos que la media o promedio está muy influenciada por **valores extremos**, mientras que la mediana no lo está.

Entonces la comparando la media con la mediana tendremos una idea de la asimetría.

Si la media es más grande que la mediana, hay asimetría en forma de una cola hacia el lado de los valores grandes.

Si la media es más pequeña que la mediana, la asimetría tiene forma de una cola hacia el lado de los valores pequeños.

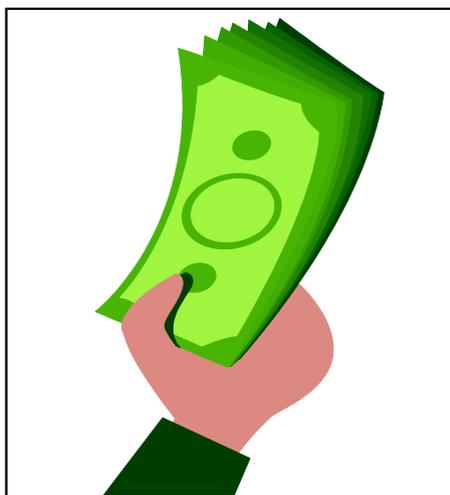
Y si la media y la mediana son parecidas, quiere decir que los datos son aproximadamente **simétricos**.

En los siguientes tres ejemplos veremos diferentes situaciones:

EJEMPLO 20

Sueldos empleados empresa ACE.

El primer conjunto de datos corresponde a los sueldos de los 50 empleados de la empresa ACE, en miles de pesos.

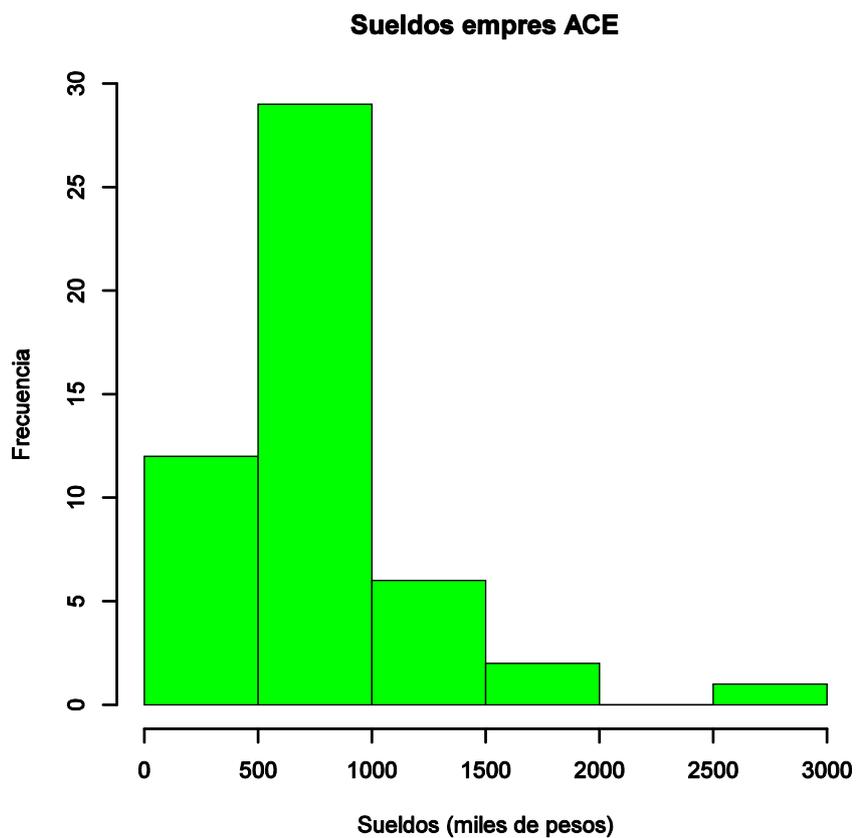


Los datos se muestran ordenados de menor a mayor, para facilitar los cálculos que llevaremos a cabo.

| | | | | | | | | | |
|------|------|------|-------|------|-----|------|------|------|------|
| 320 | 326 | 326 | 345 | 347 | 370 | 379 | 394 | 402 | 409 |
| 415 | 505 | 527 | 581,2 | 585 | 587 | 588 | 622 | 639 | 660 |
| 671 | 678 | 689 | 694,5 | 707 | 746 | 746 | 776 | 790 | 741 |
| 767 | 787 | 806 | 821,2 | 850 | 888 | 940 | 955 | 986 | 996 |
| 1033 | 1128 | 1165 | 1171 | 1181 | 285 | 1455 | 1682 | 1887 | 2675 |

Veremos un histograma de estos datos, agrupados en intervalos de 500 mil pesos. No hemos olvidado ponerle título al gráfico y a los ejes.

El eje horizontal, de los sueldos, debe llevar la unidad de medida (miles de pesos):



Observa que claramente hay un grupo grande de empleados cuyos sueldos están concentrados en valores menores que un millón, pero hay algunos que se escapan hacia valores mayores.

Esto es una **asimetría** en los datos, Particularmente, es una **asimetría positiva o a la derecha**.

En datos reales, es muy frecuente que se presenten dos características: sólo valores positivos y asimetría a la derecha.

Esto es frecuente en datos como pesos, tiempos, longitudes, capacidades, etc.

Veamos cómo son las medidas de centro y los cuartiles, en este conjunto de datos:

Cuartil 1: 510,5 mil pesos

Mediana: 700.8 mil pesos

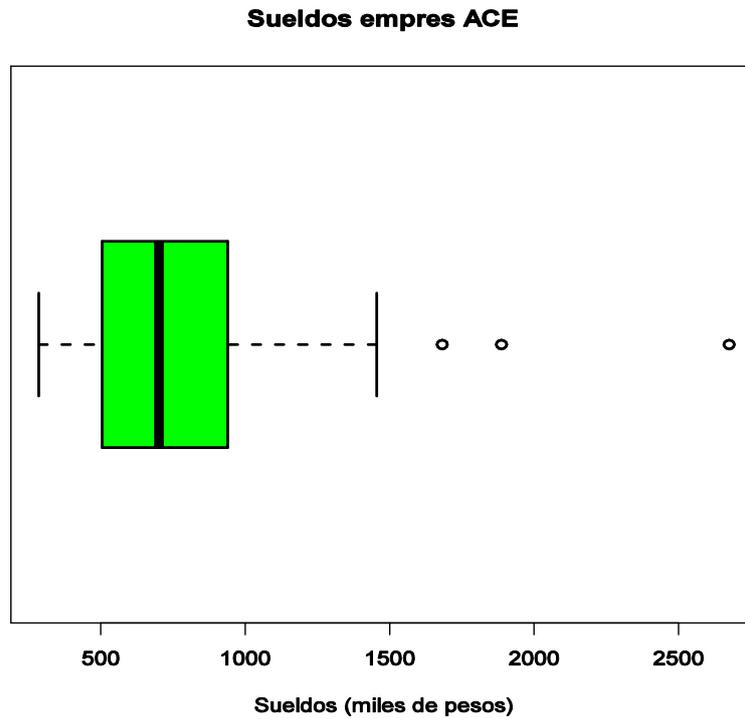
Promedio o media: 780.8 mil pesos

Cuartil 3: 927.0 mil pesos.

Observa que el promedio es más grande que la mediana, aún cuando ambas son medidas de centro.

Por supuesto que tiene que ser así, pues recuerda que el promedio está afectado por valores extremos, en cambio la mediana no: es una medida **robusta**.

Con estas medidas podemos construir el cajón con bigotes, que se muestra a continuación:



En este gráfico se aprecia la asimetría positiva o derecha, y quedan individualizados tres valores extremos, que corresponden a los sueldos más altos, 1682, 1887, y 2675, en miles de pesos.

EJEMPLO 21

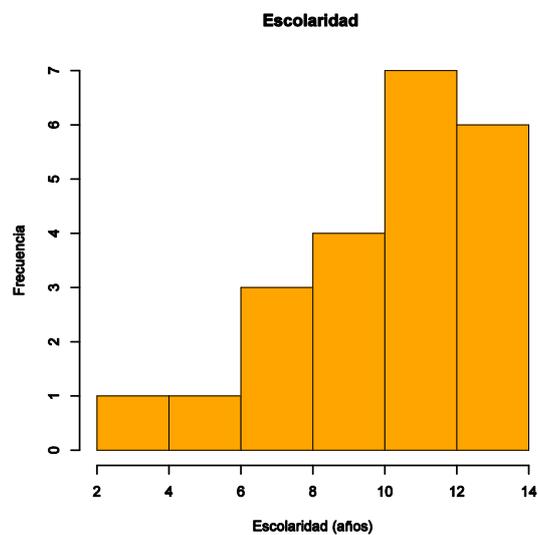
Escolaridad de habitantes de un pueblo rural.

El segundo conjunto corresponde a los años de escolaridad de una muestra de 22 habitantes de un pueblo rural.



| | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|
| 3 | 5 | 8 | 8 | 8 | 10 | 10 | 10 | 10 | 11 | 11 |
| 12 | 12 | 12 | 12 | 12 | 13 | 14 | 14 | 14 | 14 | 14 |

Los datos se resumen en el siguiente histograma, con intervalos de 2 años:



En este caso hay una asimetría inversa a los datos de los sueldos: ahora la cola está hacia la izquierda.

Se dice que la **asimetría** es **negativa** o **a la izquierda**.

Ahora las medidas de centro y los cuartiles son los siguientes:

Cuartil 1 : 22 años

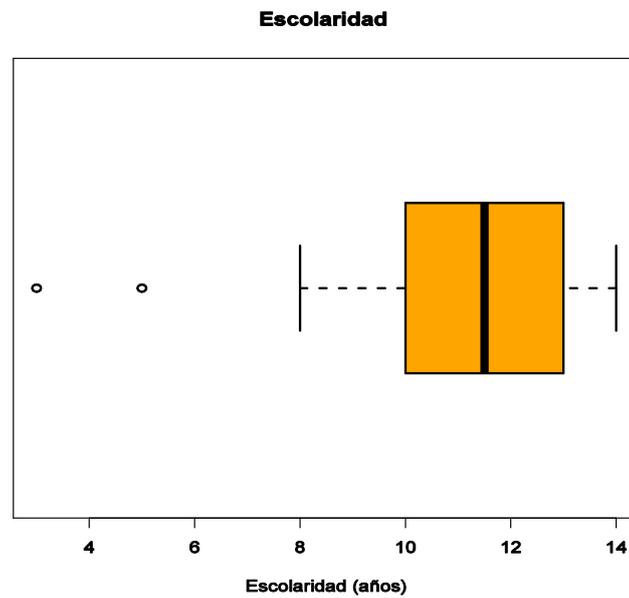
Mediana: 11,5 años

Promedio o media: 10 años

Cuartil 3: 12,75 años.

En este caso, al contrario de los sueldos, el promedio es más pequeño que la mediana, pues el promedio está influido por los datos extremos que son pequeños, y la mediana no.

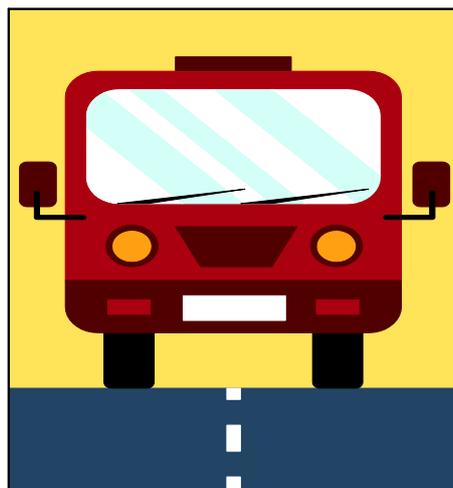
Construimos el gráfico de cajón con estas medidas, y observamos dos valores extremos:



EJEMPLO 22

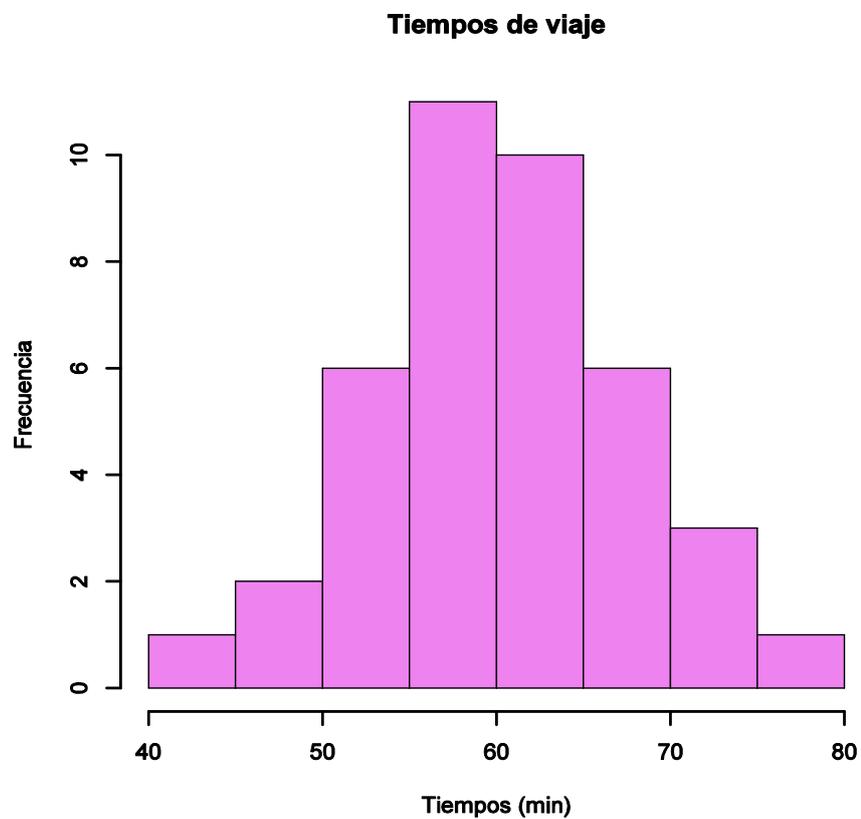
Tiempos de viaje en locomoción colectiva.

El tercer conjunto muestra los tiempos de viaje en locomoción colectiva de una muestra de 40 trabajadores, en minutos.



| | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|
| 44 | 48 | 49 | 51 | 53 | 53 | 55 | 55 | 55 | 56 |
| 56 | 58 | 58 | 59 | 59 | 59 | 59 | 60 | 60 | 60 |
| 61 | 61 | 61 | 61 | 61 | 61 | 61 | 63 | 63 | 65 |
| 66 | 67 | 67 | 67 | 69 | 70 | 72 | 74 | 75 | 76 |

El histograma, con intervalos de 5 minutos, se muestra a continuación:



Ahora vemos que, a diferencia de los anteriores conjuntos de datos, es bastante simétrico.

Las medidas de centro y los cuartiles son los siguientes:

Cuartil 1 : 56 minutos

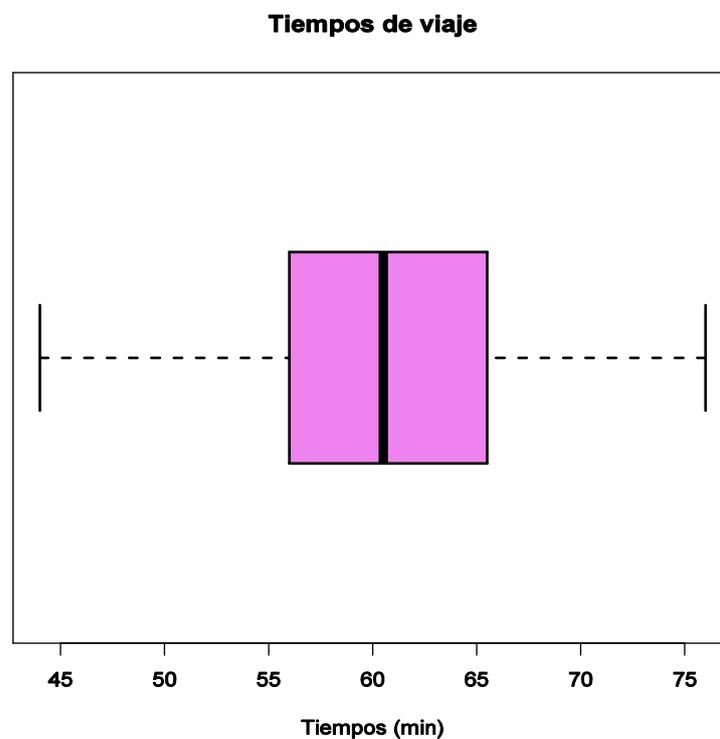
Mediana: 60,5 minutos

Promedio o media: 60,7 minutos

Cuartil 3: 65,25 minutos.

En este caso la media y la mediana casi coinciden, eso es consecuencia de que los datos son **simétricos**.

El gráfico de cajón es el siguiente:



También muestra la simetría. Y no presenta valores extremos en ninguno de los dos lados.

Podemos concluir que la diferencia de la media menos la mediana nos da una idea de la asimetría que presenta el conjunto de datos:

Si es positiva, hay asimetría a la derecha o asimetría positiva;
si es negativa, hay simetría a la izquierda o asimetría negativa,
si la diferencia es cercana a cero, hay simetría.

EJEMPLO 23

Tiempos de viaje en locomoción colectiva con valores extremos.

Vamos a hacer el siguiente experimento para comprobar la robustez (resistencia a valores extremos) o falta de ella de las medidas de centro y los cuartiles.

Tomemos el tercer conjunto de datos del Ejemplo anterior: los tiempos de viaje en locomoción colectiva de una muestra de 40 trabajadores, en minutos.

Recordemos que:

el Cuartil 1 es 56,0 minutos

La Mediana es 60,5 minutos

el Promedio es 60,7 minutos

el Cuartil 3 es 65,25 minutos.

Ahora vamos a suponer que en lugar de 40 datos, hay 42, y que los que faltaron viven lejos de su lugar de trabajo, y se demoran 190 y 195 minutos, respectivamente.

Claramente son valores extremos. Si recalculamos las medidas, obtenemos los siguientes valores:

el nuevo cuartil 1 es 56,5 minutos

La mediana queda en 61,0 minutos

el promedio queda en 66,98 minutos

el cuartil 3 queda en 66,75 minutos.

Puedes observar que el promedio aumentó en 6,28 minutos, lo que, en porcentaje, corresponde a $100 \times 6,28 / 60,7 = 10,3\%$. Bastante grande el cambio.

Por otro lado, la mediana aumentó en 0,5 minutos, lo que representa apenas un $100 \times 0,5 / 60,7 = 0,82\%$.

El cambio en la mediana es mínimo por la introducción de estas dos observaciones extremas, en cambio el promedio aumentó más de un 10% .

Por eso decimos que la mediana es robusta, mientras que el promedio no lo es.

Si comparamos los cuartiles, vemos que el cuartil 1 y el cuartil 3 aumentaron en 0,5 y 1,5 minutos, respectivamente. En términos porcentuales son, respectivamente un $0,89\%$ y un $0,77\%$.

Estos cambios son muy pequeños, comparados con el aumento en el promedio.

EJERCICIOS

13) En relación al Ejemplo 20, realiza los cálculos para obtener el promedio, la mediana y los cuartiles. Construye el diagrama de cajón.

14) En relación al Ejemplo 21, realiza los cálculos para obtener el promedio, la mediana y los cuartiles. Construye el diagrama de cajón.

15) En relación al Ejemplo 22, realiza los cálculos para obtener el promedio, la mediana y los cuartiles. Construye el diagrama de cajón.

16) En relación al Ejemplo 23, realiza los cálculos para obtener el promedio, la mediana y los cuartiles. Construye el diagrama de cajón.

17) En relación a los datos de las detenciones de la máquina envasadora de jugo, del Ejercicio 8, construye un diagrama de cajón.

Compáralo con el histograma.

18) En relación a los datos del Ejercicio 10, de la precipitación de azúcar en la sangre, construye un diagrama de cajón.

Compáralo con el histograma.

11. Medidas de dispersión

¿Mis datos, cuán distintos son entre ellos?

Hemos visto lo que son algunas medidas de centro y de posición, que tienen por objeto mostrar, a groso modo, dónde están los datos.

Pero también hay medidas que muestran cuanta dispersión hay en los datos numéricos: si están más o menos concentrados en torno al promedio, y si se dispersan hacia ambos lados, mostrando cuán separados están.

Las más conocidas son la **varianza**, la **desviación estándar** y el **coeficiente de variación**.

La **varianza** es un promedio de los cuadrados de las desviaciones de las observaciones respecto de la media.

La forma de calcular la varianza es la siguiente:

Primero se obtiene el promedio de los datos

Luego se le resta el promedio a cada uno de los datos. Estos valores representan las desviaciones en torno al promedio, es decir, en torno al centro.

Estas diferencias o desviaciones se elevan al cuadrado.

Después se suman y se dividen por $n-1$, en que n es el número de observaciones.

¿Por qué se elevan al cuadrado? Porque algunas observaciones son mayores que el promedio, y otras son menores. Si son mayores, al restarles el promedio van a dar valores positivos, y si son menores, darán valores negativos.

La suma de positivos y negativos tenderá a dar cero, pues unos y otros se van a anular. No nos sirve que dé cero, porque no mide nada.

Pero al elevarlos al cuadrado, darán todos positivos, pues un número negativo elevado al cuadrado resulta positivo.

Y mientras más difieran los valores del promedio, más grande será el valor del cuadrado. Por lo tanto, mientras más dispersos están los datos, más grande será la suma.

Finalmente, se divide por $n-1$. ¿Por qué por $n-1$ y no por n , si queremos obtener el promedio de las desviaciones?

La explicación es que la dispersión o variabilidad es una característica poco favorable: el ideal es que los datos sean parecidos unos con otros. Mucha dispersión significa desorden.

Pero al usar los mismos datos para calcular el promedio y luego para calcular la varianza, se tiende a ajustar demasiado esta última a los datos. Por lo que nuestra varianza va a tender a quedar sub-valorada.

Al dividir por $n-1$ en lugar de por n , tendemos a aumentar un poco el cálculo de la varianza, con lo que tendemos a compensar el hecho que esté sobreajustada.

Otra manera de verlo es que, si a cada dato le restamos el promedio y sumamos todos estos términos, nos da cero, como ya dijimos, sin importar cómo son los datos.

Eso significa que uno de ellos, cualquiera, depende de los otros. Se puede calcular si se conocen todos los demás. Por lo tanto, se puede decir que son $n-1$ valores "independientes".

Se usa el símbolo S^2 para representar la varianza.

Observemos que las desviaciones en torno al promedio se elevaron al cuadrado. Por lo tanto, su unidad de medida es el cuadrado de las unidades en que se midieron las observaciones originales.

Por ejemplo, si los datos representan kilos, la varianza se expresa en kilos al cuadrado. Si los datos son metros, la varianza se expresa en metros al cuadrado.

Hay una forma alternativa de calcular la varianza, que da exactamente el mismo resultado, pero que es más fácil de calcular:

Consiste en sumar los cuadrados de las observaciones originales y restarles el promedio al cuadrado, multiplicado por n , el número de observaciones.

Finalmente, el resultado se divide por $n-1$.

EJEMPLO 24

Notas de Ciencias Sociales (varianzas).

Vamos a calcular la varianza de las notas de Ciencias Sociales, para tener una idea de la dispersión que exhiben esos datos.

La tabla siguiente contiene los datos y la tabla que sigue, los cuadrados:

| | | | | |
|-----|-----|-----|-----|-----|
| 5,2 | 4,6 | 6,2 | 5,9 | 7,0 |
| 4,9 | 5,8 | 3,2 | 6,1 | 5,8 |
| 6,5 | 4,9 | 2,4 | 6,0 | 4,8 |
| 3,2 | 4,8 | 5,9 | 6,2 | 4,7 |
| 6,8 | 3,2 | 5,3 | 4,2 | 6,5 |

| | | | | |
|-------|-------|-------|-------|-------|
| 27,04 | 21,16 | 38,44 | 34,81 | 49,00 |
| 24,01 | 33,64 | 10,24 | 37,21 | 33,64 |
| 42,25 | 24,01 | 5,76 | 36,00 | 23,04 |
| 10,24 | 23,04 | 34,81 | 38,44 | 22,09 |
| 46,24 | 10,24 | 28,09 | 17,64 | 42,25 |

La suma de las notas es 130,1 y la suma de los cuadrados es 713,33.

La suma de los cuadrados de las notas menos la suma de las notas al cuadrado dividido por $n = 25$ es $713.33 - 130.1 \times 130.1^2/25 = 36,2896$

La varianza es ese número dividido por $n - 1 = 24$:

$s^2 = 36,2896 / 24 = 1,5121$. Si las notas se miden en puntos, la varianza se mide en puntos al cuadrado.

Como vimos, la unidad de medida de la **varianza** es el cuadrado de las unidades de medida originales. Si estas últimas son litros, la varianza se expresa en litros al cuadrado; si son volts, la varianza será volts al cuadrado.

Eso es incómodo y difícil de interpretar. Tenemos otra medida de dispersión que se mide en las mismas unidades de medida que los datos originales.

Es la **desviación estándar**, que no es más que la raíz cuadrada de la varianza.

La desviación estándar, por su facilidad de interpretación en términos de la medida de los datos originales, es más usada que la varianza como medida de dispersión. Se simboliza por s .

Por último, debido al hecho que, para el cálculo de estas dos medidas de dispersión, la varianza y la desviación estándar, se debe elevar las dispersiones individuales al cuadrado, resulta que están fuertemente influenciadas por **valores extremos**.

La desviación estándar tiene el inconveniente que depende de la unidad de medida de los datos originales. Por esa razón, en una situación particular no es fácil saber si es grande o es pequeña. También resulta difícil comparar las dispersiones de dos conjuntos de datos que se miden en unidades diferentes.

Por ejemplo, supongamos que unos datos se expresan en metros, y su desviación estándar resulta ser 45 metros. Su varianza es el cuadrado de 45, es decir, 2025 metros al cuadrado.

Pues bien, si transformamos esos datos a centímetros, hay que multiplicar la desviación estándar por 100, por lo que la desviación estándar es 4500 centímetros. La varianza hay que multiplicarla por 10000, luego sería 450000 cm^2 .

Otra medida de dispersión es el **rango**, que consiste en la diferencia entre el valor máximo menos el valor mínimo.

Pero te podrás dar cuenta que esta medida depende sólo de los dos valores más extremos. Por eso es una muy mala medida de dispersión, y sólo tiene aplicación en un limitado número de situaciones. Por lo tanto, nos olvidaremos de ella.

Pero hay una medida parecida al rango, pero que no depende de valores extremos. Ya la definimos antes, cuando vimos los **cuartiles**.

Se trata del **rango intercuartil**, que consiste en la diferencia entre el **cuartil 3** menos el **cuartil 1**.

Recordemos que el cuartil 1 divide el conjunto de datos en un 25% a la izquierda (menores o iguales a él) y un 75% a la derecha (mayores o iguales a él).

El cuartil 3 divide el conjunto de datos en un 75% a la izquierda y un 25% a la derecha.

Es decir, el **rango intercuartil** depende del cincuenta por ciento de las observaciones centrales, que constituyen el 50% más representativo del conjunto de datos. Por eso, es considerada una medida de dispersión **robusta**.

Por último, tenemos una medida de dispersión que no depende de la unidad de medida de los datos.

Es el **coeficiente de variación**. Se define como el cociente entre la desviación estándar y el promedio.

Pero sólo tiene sentido si los datos corresponden a una variable que sólo admite **valores positivos**.

Efectivamente, pues si no fuera así, el promedio podría ser cero o negativo. No podríamos dividir por cero, y si el coeficiente de variación fuese negativo, no sabríamos cómo interpretarlo.

¿En qué unidad de medida se expresa el **coeficiente de variación**?

Veamos: La desviación estándar queda expresada en la misma unidad que los datos originales. Pero el promedio también. Por lo tanto, al hacer el cociente, vemos que el coeficiente de variación no tiene unidad de medida.

Por eso esta medida permite comparar dispersiones de datos medidos en diferentes unidades de medida.

Por estar calculada en términos de la desviación estándar, el coeficiente de variación también resulta que está fuertemente influenciado por **valores extremos**.

EJEMPLO 25

Tres casos que muestran diversos grados de dispersión

Veamos la figura siguiente, que muestra tres histogramas que corresponde a tres conjuntos de datos con diferentes características.

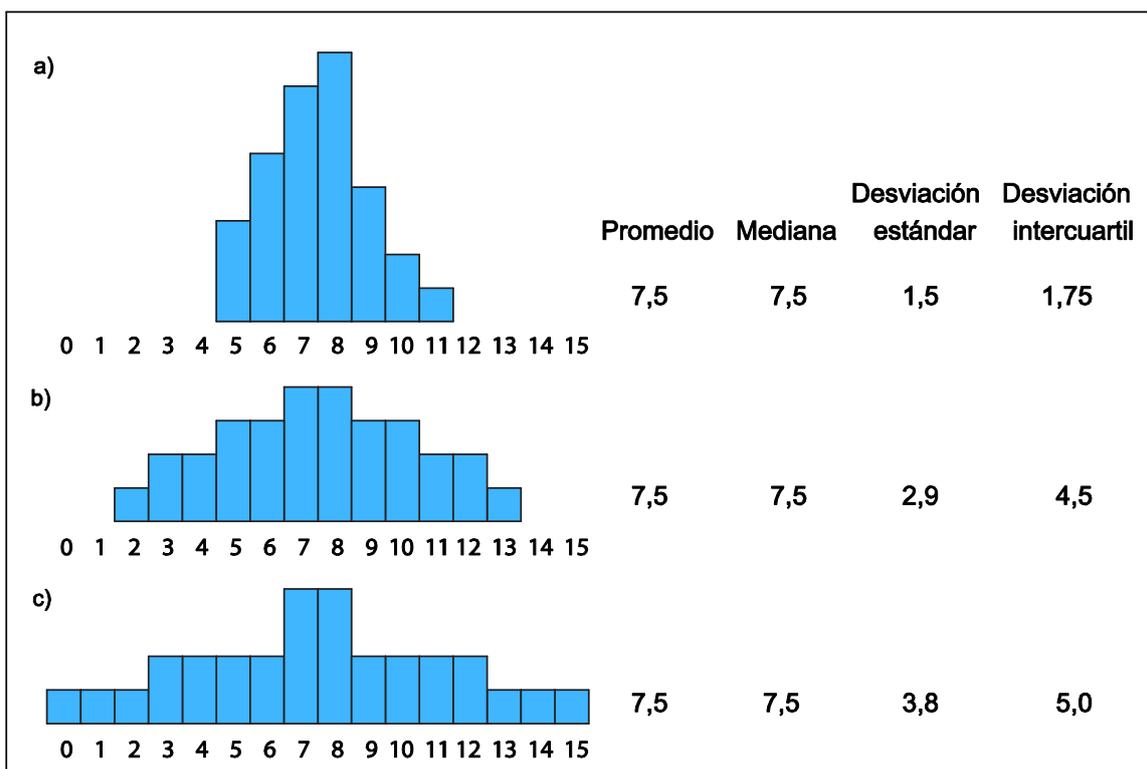
Primero, observemos que los tres conjuntos tienen el mismo promedio, 7,5, y la misma mediana, también 7,5. Ambas medidas coinciden debido a la simetría

que muestran los tres histogramas. Sin embargo, difieren bastante, en cuanto a la **dispersión**.

En el caso a), los datos están concentrados en torno al centro. La desviación estándar es 1,5 y el **rango intercuartil** es 1,75. Son dos diferentes medidas de dispersión.

En el caso b) se puede observar que la dispersión es mayor. Eso se refleja en la desviación estándar, que es 2,9, y en el **rango intercuartil**, que es 4,5. Ambas medidas de dispersión son mayores que en el caso a).

En el caso c) hay más dispersión que en los casos anteriores. Por eso la **desviación estándar** y el **rango intercuartil** son ambos más grandes que las correspondientes en los casos anteriores.



EJEMPLO 26

Notas de Ciencias Sociales (desv. estándar).

En el Ejemplo 24 vimos que la varianza es $s^2 = 1,5121$ puntos al cuadrado.

Por lo tanto la desviación estándar es $s = \sqrt{1,5121} = 1,2297$ puntos.

El promedio, calculado en el Ejemplo 16, es 5,204 puntos,

y por lo tanto el coeficiente de variación es $1,2297 / 5,204 = 0,2363$

sin unidad de medida.

EJEMPLO 27

Tasas de interés bancario.

Se tienen 20 observaciones que corresponden a tasas de interés anual de depósitos, en porcentaje, al momento de tomar las observaciones, de 20 bancos de un sector geográfico.

Se ha agregado una columna con los cuadrados.

| Banco | Tasa | Tasa ² | Banco | Tasa | Tasa ² | Banco | Tasa | Tasa ² |
|-------|------|-------------------|-------|------|-------------------|-------|------|-------------------|
| 1 | 5,2 | 27,04 | 8 | 4,0 | 16,00 | 15 | 5,7 | 32,49 |
| 2 | 6,1 | 37,21 | 9 | 3,6 | 12,96 | 16 | 6,1 | 37,21 |
| 3 | 3,4 | 11,56 | 10 | 5,6 | 31,36 | 17 | 6,0 | 36,00 |
| 4 | 4,8 | 23,04 | 11 | 4,7 | 22,09 | 18 | 3,9 | 15,21 |
| 5 | 4,5 | 20,25 | 12 | 5,8 | 33,64 | 19 | 3,6 | 12,96 |
| 6 | 3,8 | 14,44 | 13 | 6,4 | 40,96 | 20 | 4,7 | 22,09 |
| 7 | 4,7 | 22,09 | 14 | 3,3 | 10,89 | | | |
| | | | | | | Sumas | 95,9 | 479,49 |

La varianza es $s^2 = (479,49 - 95,9^2/11) / 19 = 1,0342$ por ciento al cuadrado.

La desviación estándar es $s = 1,0169$ por ciento

El coeficiente de variación es $CV = 0,2121$

Podemos comparar estos resultados con los del Ejemplo anterior.

La desviación estándar en este caso es mucho menor. Pero no son comparables, por el hecho que las observaciones están medidas en diferentes escalas.

Pero los coeficientes de variación sí son comparables. Resulta que el CV es un poco menos en este ejemplo que en el anterior, muy poco. Por lo que hay un poco menos dispersión en las tasas de interés que en las notas de Ciencias Sociales, pero muy poco menos.

EJERCICIOS

19) En la industria textil se limpian las fibras de algodón por diferentes métodos. Luego de forma una especie de paño esponjoso con ellas, de unos centímetros de grosor y aproximadamente un metro de ancho, que se enrolla en balas cilíndricas de 20 metros cada una.

Este material luego se va comprimiendo y torciendo hasta formar el hilo.

Se requiere que el grosor del hilo sea uniforme. Para que esto ocurra, el paño debe tener un peso uniforme.

Con el objeto de controlar que la densidad de este paño sea uniforme durante su fabricación, cada cierto tiempo se corta un trozo de un metro de largo y se pesa.

La tabla siguiente contiene los datos, medidos en gramos.

| | | | | | |
|---|-----|----|-----|----|-----|
| 1 | 208 | 10 | 178 | 19 | 232 |
| 2 | 199 | 11 | 230 | 20 | 207 |
| 3 | 232 | 12 | 221 | 21 | 207 |
| 4 | 210 | 13 | 209 | 22 | 180 |
| 5 | 228 | 14 | 187 | 23 | 210 |
| 6 | 221 | 15 | 238 | 24 | 224 |
| 7 | 181 | 16 | 225 | 25 | 220 |
| 8 | 205 | 17 | 224 | | |
| 9 | 198 | 18 | 196 | | |

Obtén la desviación estándar y el coeficiente de variación. Construye un histograma con estos datos.

20) Como parte de un estudio de mercado, se registraron los precios de un tipo específico de neumático en una zona determinada del país.

Los datos obtenidos son los siguientes, en miles de pesos:

| | | | | | |
|---|-------|----|-------|----|-------|
| 1 | 24,73 | 7 | 36,42 | 13 | 58,64 |
| 2 | 42,50 | 8 | 36,86 | 14 | 83,12 |
| 3 | 28,99 | 9 | 38,18 | 15 | 42,40 |
| 4 | 31,15 | 10 | 45,80 | 16 | 70,80 |
| 5 | 36,85 | 11 | 58,95 | | |
| 6 | 82,35 | 12 | 48,15 | | |

Obtén la desviación estándar y el coeficiente de variación. Compara la dispersión con la dispersión de los datos del Ejercicio 19.

Construye un histograma y compáralo con el histograma del Ejercicio 19.

21) Se midieron los voltajes de salida de un grupo de 18 fuentes de porder.

Los datos, en volts, son los siguientes:

| | | | | | |
|---|------|----|------|----|------|
| 1 | 12,8 | 7 | 10,9 | 13 | 17,2 |
| 2 | 14,2 | 8 | 10,1 | 14 | 8,0 |
| 3 | 13,2 | 9 | 9,8 | 15 | 11,2 |
| 4 | 18,7 | 10 | 10,6 | 16 | 9,7 |
| 5 | 11,3 | 11 | 11,7 | 17 | 12,5 |
| 6 | 10,6 | 12 | 13,2 | 18 | 15,1 |

Obtén la desviación estándar y el coeficiente de variación. Construye un histograma. Compara la dispersión con lo obtenido en los ejercicios 19 y 20.

Respuestas:

19) DE = 17,3070 gm CV = 0,0829

20) DE = 18,0707 mil pesos CV = 0,3775

21) DE = 2,7111 volts CV = 0,2210

12. Medidas de asociación entre variables

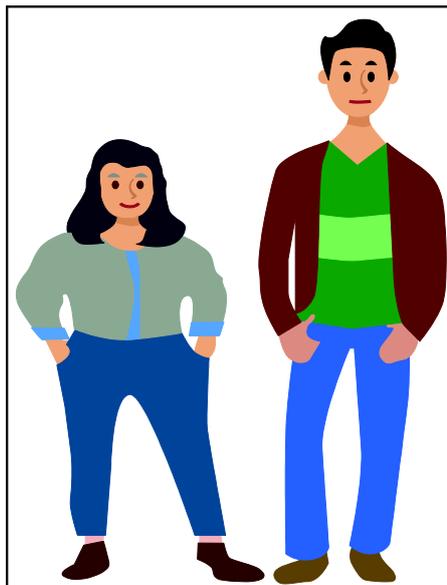
¿Cada una por su lado, o tienen alguna vinculación?

MOTIVACIÓN

Consideremos las dos características de un grupo de personas: la altura y el peso.

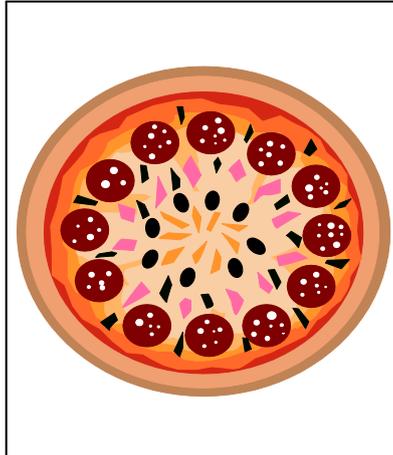
Es evidente que en la mayoría de los casos las personas de mayor altura tienden a tener más peso.

En este caso decimos que hay una **asociación positiva** entre esas dos características.



Aunque en algunos casos particulares puede haber una persona con más altura que otra, pero con menos peso, pero serían excepcionales.

En otra situación consideremos el precio de un producto, como, por ejemplo, las paltas, y el consumo de ese producto. Si el precio de las paltas empieza a subir, las personas comienzan a consumir menos paltas, sustituyéndolas por otros productos. El consumo comienza a bajar.



Aquí decimos que las características *precio* y *consumo* de un producto tienen una **asociación negativa**.

Por último, consideremos las características *venta semanal de pizzas en Iquique* y *venta semanal de pizzas en Rancagua*.

Es muy posible que el aumento de una de ellas no implica un aumento de la otra.

Si es así, decimos que **no hay asociación** entre las características.

Consideremos dos variables medidas a un conjunto de objetos.

Veremos el grado en que estas dos variables están **asociadas**.

El que estén asociadas significa que si una aumenta, la otra tiende a aumentar, o bien, si una aumenta, la otra tiende a disminuir.

Por el contrario, si una aumenta la otra puede aumentar, disminuir o mantenerse estable, sin un patrón definido, decimos que **no hay asociación** entre esas variables.

EJEMPLO 28

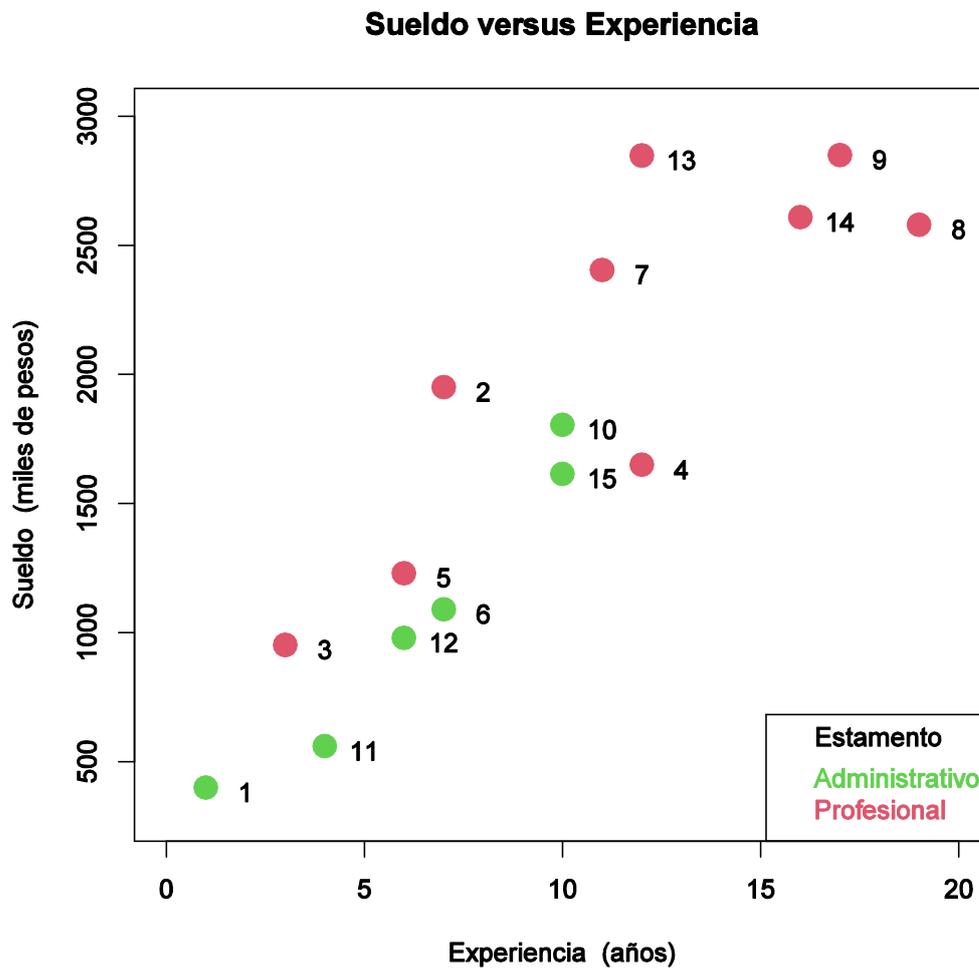
Experiencia y sueldos de funcionarios.

La tabla siguiente presenta lo años de experiencia y los sueldos de una muestra de 15 funcionarios profesionales.

El Estamento indica si es Profesional (1) o Administrativo (2).

| Funcionario | X - Años de experiencia | Y - Sueldo en miles de pesos | Estamento |
|-------------|-------------------------|------------------------------|-----------|
| 1 | 1 | 400 | 2 |
| 2 | 7 | 1951 | 1 |
| 3 | 3 | 952 | 1 |
| 4 | 12 | 1650 | 1 |
| 5 | 6 | 1230 | 1 |
| 6 | 7 | 1090 | 2 |
| 7 | 11 | 2405 | 1 |
| 8 | 19 | 2580 | 1 |
| 9 | 17 | 2850 | 1 |
| 10 | 10 | 1805 | 2 |
| 11 | 4 | 560 | 2 |
| 12 | 6 | 980 | 2 |
| 13 | 12 | 2848 | 1 |
| 14 | 16 | 2609 | 1 |
| 15 | 10 | 1615 | 2 |

Representaremos los datos en un gráfico de dispersión:



Se puede apreciar la asociación de tipo lineal existente entre ambas variables observadas.

Es decir, los puntos parecen estar repartidos aproximadamente en torno a una línea diagonal imaginaria.

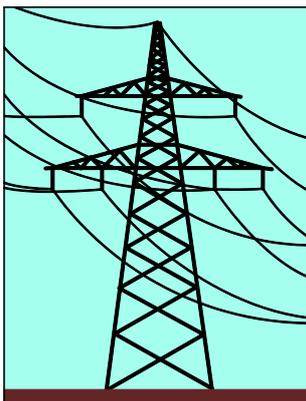
Además, esta línea tiende a subir a medida que nos movemos hacia la derecha. O sea, si una variable crece, la otra tiende a crecer.

Como dijimos antes, esta es una **asociación positiva**.

EJEMPLO 29

Generación de energía eléctrica.

Los datos siguientes corresponden a la generación de energía eléctrica durante el año 2007.



| Mes | Trimestre | Térmica (X) | Hidráulica (Y) |
|-----|-----------|-------------|----------------|
| Ene | 1 | 1475 | 2480 |
| Feb | 1 | 1549 | 2158 |
| Mar | 1 | 1741 | 2307 |
| Abr | 2 | 1863 | 1868 |
| May | 2 | 2172 | 1790 |
| Jun | 2 | 2486 | 1525 |
| Jul | 3 | 2560 | 1700 |
| Ago | 3 | 2654 | 1427 |
| Sep | 3 | 2260 | 1594 |
| Oct | 4 | 1934 | 2004 |
| Nov | 4 | 1775 | 2036 |
| Dic | 4 | 2196 | 1874 |

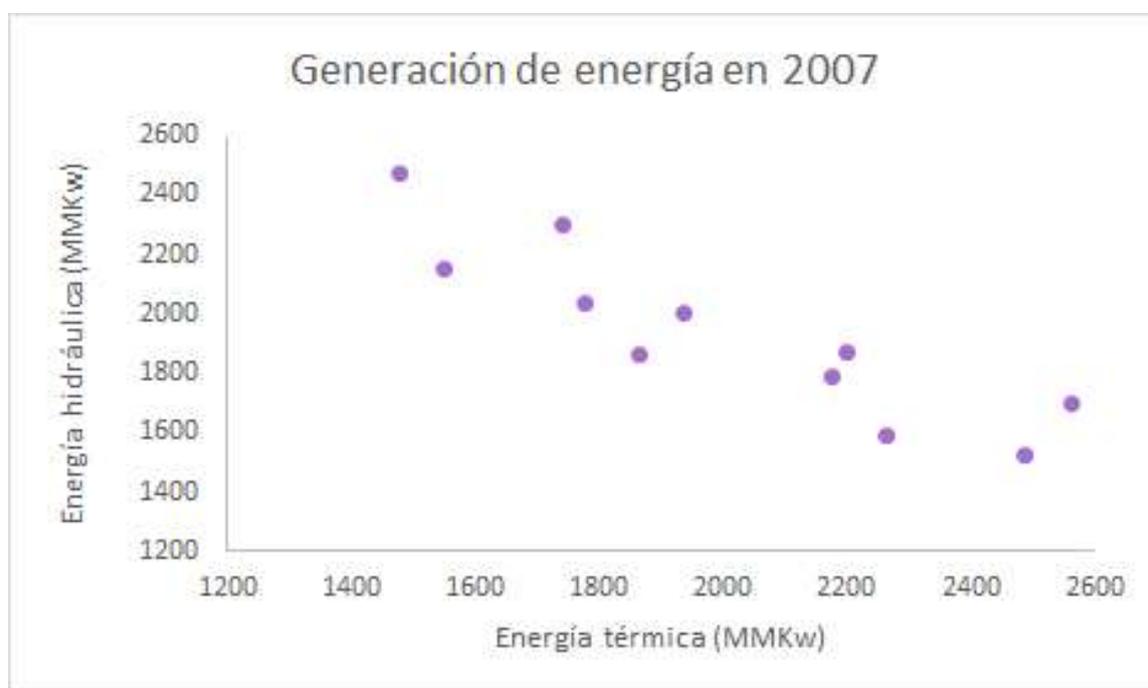
Muestra el mes, el trimestre, los millones de kilowatts (MMKw) producidos por generación térmica (a partir de combustibles fósiles, como carbón, petróleo) y

los millones de kilowatts producidos por generación hidráulica (por movimiento de agua debido a desniveles, que mueven turbinas).

Fuente: Banco Central de Chile

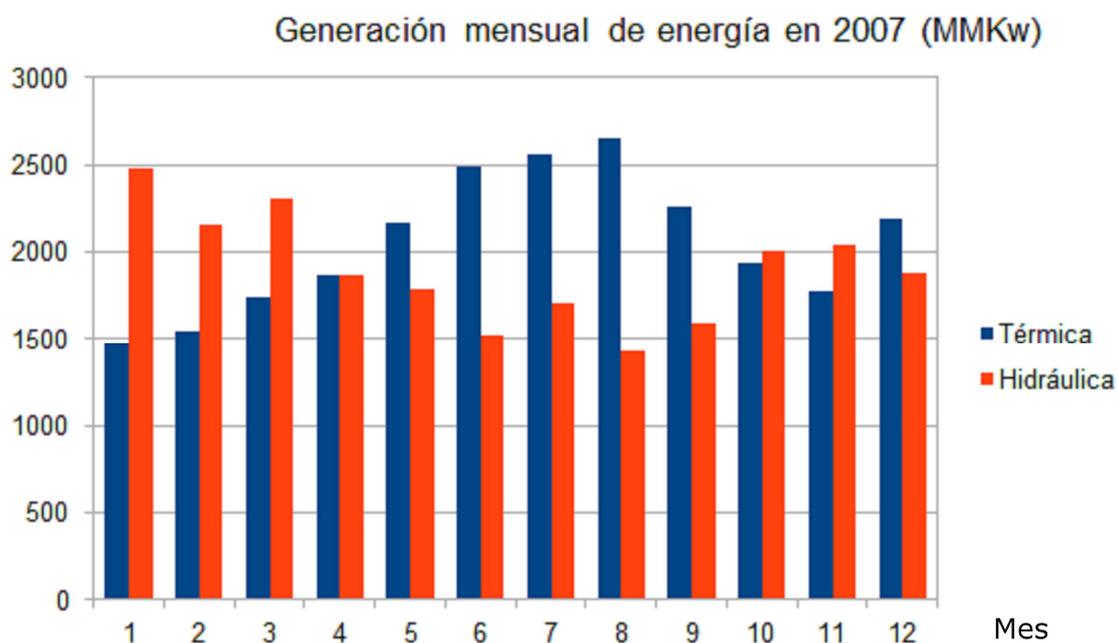
Primero usaremos Excel para visualizar estos datos.

El siguiente gráfico es un diagrama de dispersión que muestra la energía térmica generada versus la energía hidráulica, en cada uno de los meses.

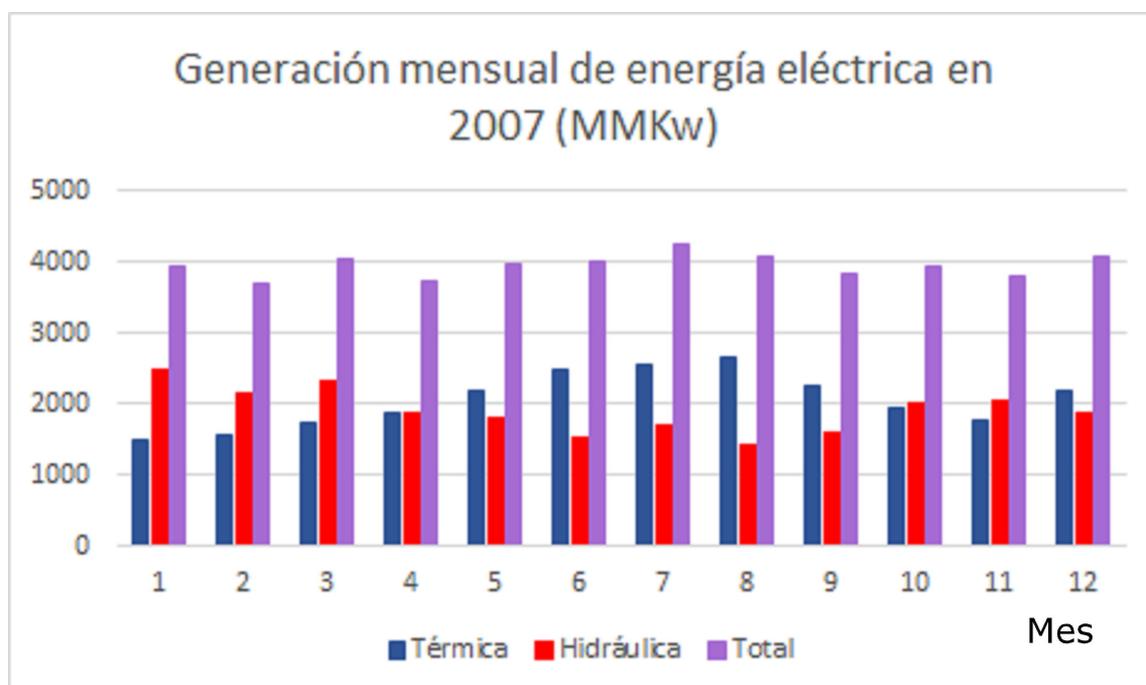


Ahora mostramos un gráfico de barras de ambas energías generadas, por mes.

Vemos que a medida que aumenta una, disminuye la otra.



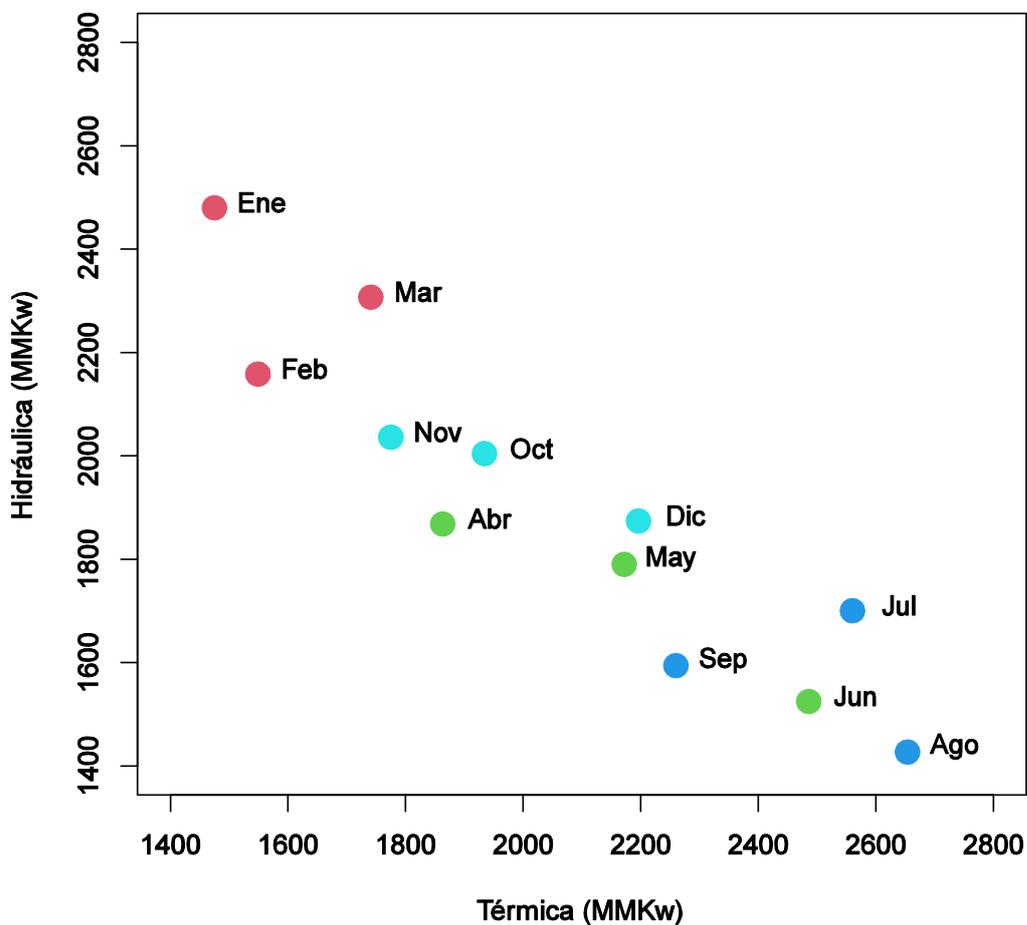
A continuación, el mismo gráfico, con los totales por mes, que se ven casi constantes a través de los meses.



Usaremos R para producir un diagrama de dispersión similar al anterior, en que el eje horizontal (de las abscisas) tiene la generación por medios térmicos y el eje vertical (de las ordenadas) tiene la generación por medios hidráulicos, en millones de kilowatts.

El gráfico nos muestra lo que ya habíamos visto, que a medida que hay más generación hidráulica, hay menos generación térmica, y vice-versa: hay una asociación negativa.

Generación de energía en 2007



Hemos agregado colores distintos a cada trimestre. Esto nos muestra que de enero a marzo hay más generación hidráulica.

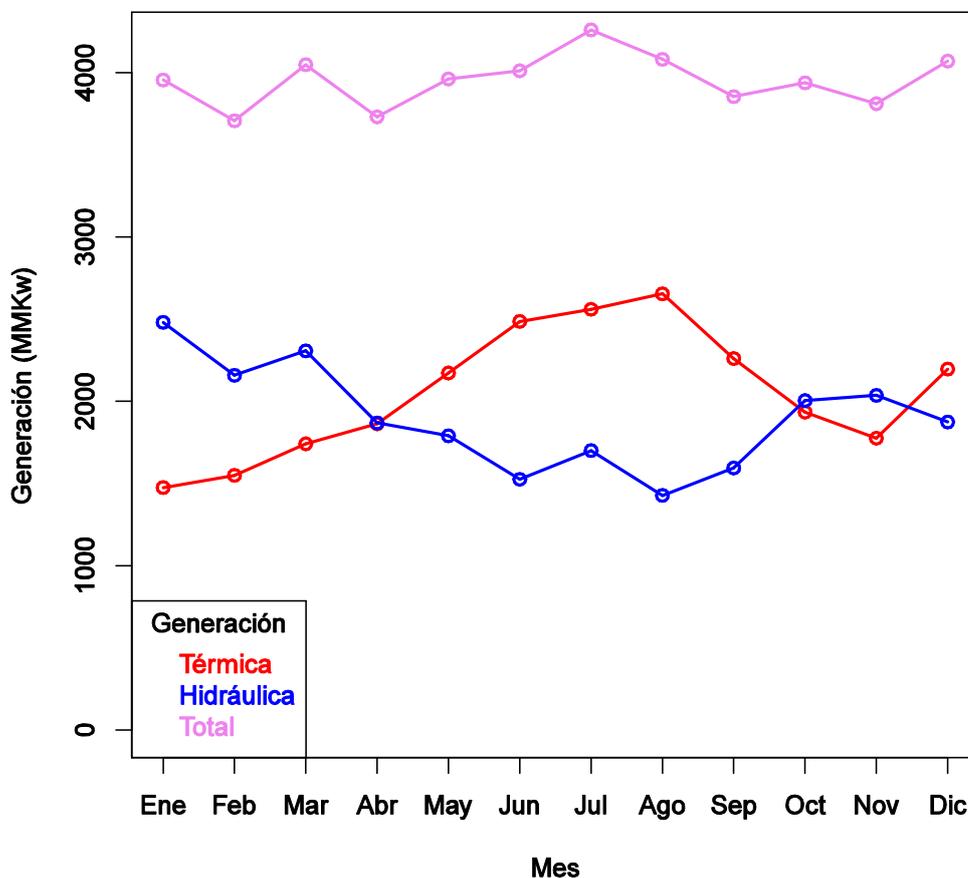
Puede ser porque el derretimiento de las nieves produce mayores caudales de agua en los ríos en que están las centrales eléctricas.

De junio a septiembre, fines de junio e invierno, hay más generación térmica, seguramente por las nevadas en las fuentes de los ríos.

Además, se aprecia que la relación es más o menos lineal. Y que la suma es aproximadamente constante.

El siguiente diagrama de dispersión tiene el mes en el eje horizontal y la generación de cada tipo y la suma en el eje vertical.

Generación eléctrica en 2007



Por cada una se han unido los puntos para poder diferenciarlas con más facilidad.

En este gráfico se ve que mientras la generación hidráulica disminuye, la generación térmica aumenta, aunque la suma de ambas es aproximadamente constante, aumentando moderadamente en el mes de julio.

Observa que la escala vertical comienza desde cero. Si no partiera de cero, el gráfico daría una visión distorsionada.

Eso lo debe manejar el usuario, pues usualmente los programas fijan los límites de forma automática para que las curvas quepan justo dentro del área del gráfico.

EJEMPLO 30

Gastos empresas de transporte.

Un grupo de 46 empresas de transporte terrestre, llevan registro de los gastos efectuados durante un año, en 8 rubros, en millones de pesos. Son los siguientes datos:

Las variables medidas a cada empresa son:

Id - Identificador de la empresa

RT - Revisión técnica

MU - Materiales y útiles

Tel - Telefonía

Pr - Primas de seguros

Mnt - Mantenimiento

GPS - Servicios de GPS

GO - Gastos de Operación

IGP - Impuestos aduana, contribuciones, patentes

Prm - Promedio

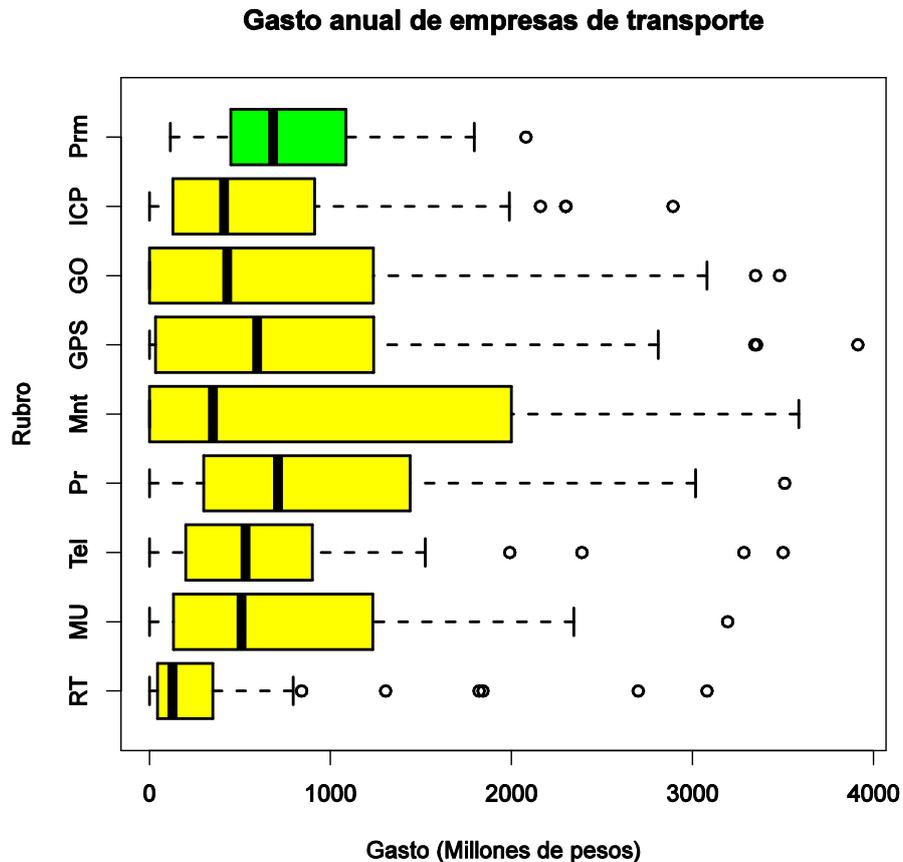
| Id | RT | MU | Tel | Pr | Mant | GPS | GO | ICP | Prm |
|----|------|------|------|------|------|------|------|------|------|
| 1 | 166 | 2345 | 769 | 1115 | 0 | 0 | 2300 | 837 | 942 |
| 2 | 2700 | 900 | 0 | 2850 | 3489 | 500 | 654 | 1850 | 1618 |
| 3 | 82 | 1775 | 2389 | 534 | 737 | 2689 | 412 | 71 | 1086 |
| 4 | 122 | 42 | 210 | 450 | 1225 | 200 | 0 | 100 | 294 |
| 5 | 1305 | 1380 | 1256 | 1654 | 2658 | 1239 | 0 | 2160 | 1457 |
| 6 | 0 | 7 | 405 | 0 | 0 | 1296 | 397 | 47 | 269 |
| 7 | 246 | 1763 | 294 | 2849 | 1346 | 3913 | 2005 | 1953 | 1796 |

| Id | RT | MU | Tel | Pr | GPS | GO | ICP | Prm | Mant |
|----|------|------|------|------|------|------|------|------|------|
| 8 | 201 | 1140 | 774 | 3509 | 0 | 0 | 702 | 322 | 831 |
| 9 | 41 | 630 | 397 | 195 | 0 | 628 | 3348 | 174 | 677 |
| 10 | 300 | 0 | 300 | 300 | 0 | 475 | 0 | 300 | 209 |
| 11 | 63 | 323 | 882 | 1040 | 76 | 0 | 458 | 138 | 373 |
| 12 | 1821 | 1123 | 894 | 1837 | 3200 | 2810 | 2060 | 2892 | 2080 |
| 13 | 100 | 200 | 180 | 200 | 0 | 34 | 420 | 147 | 160 |
| 14 | 0 | 963 | 1991 | 758 | 1215 | 1122 | 126 | 189 | 796 |
| 15 | 200 | 0 | 456 | 300 | 0 | 1266 | 445 | 0 | 333 |
| 16 | 94 | 237 | 900 | 0 | 2418 | 345 | 0 | 130 | 516 |
| 17 | 100 | 50 | 200 | 500 | 2000 | 300 | 0 | 100 | 406 |
| 18 | 298 | 265 | 432 | 778 | 711 | 720 | 345 | 456 | 501 |
| 19 | 24 | 1254 | 0 | 720 | 0 | 1728 | 0 | 267 | 499 |
| 20 | 93 | 186 | 756 | 347 | 782 | 0 | 2348 | 893 | 676 |
| 21 | 40 | 557 | 1500 | 1595 | 0 | 0 | 1234 | 205 | 641 |
| 22 | 100 | 50 | 200 | 500 | 2000 | 300 | 126 | 100 | 422 |
| 23 | 450 | 1234 | 300 | 200 | 0 | 541 | 800 | 210 | 467 |
| 24 | 45 | 236 | 0 | 175 | 0 | 0 | 456 | 17 | 116 |
| 25 | 520 | 30 | 0 | 200 | 0 | 234 | 2225 | 1089 | 537 |
| 26 | 3080 | 720 | 372 | 1000 | 0 | 1000 | 0 | 900 | 884 |
| 27 | 138 | 2013 | 580 | 2732 | 358 | 3354 | 2539 | 713 | 1553 |
| 28 | 1843 | 515 | 1089 | 886 | 1225 | 1782 | 2710 | 1892 | 1493 |
| 29 | 140 | 3194 | 1182 | 500 | 267 | 677 | 0 | 450 | 801 |
| 30 | 756 | 1129 | 1524 | 3017 | 0 | 0 | 2467 | 524 | 1177 |
| 31 | 0 | 2166 | 0 | 0 | 342 | 127 | 13 | 0 | 331 |

| Id | RT | MU | Tel | Pr | GPS | GO | ICP | Prm | Mant |
|----|-----|------|------|------|------|------|------|------|------|
| 32 | 1 | 1377 | 141 | 619 | 75 | 1660 | 636 | 1083 | 699 |
| 33 | 80 | 133 | 982 | 504 | 3587 | 850 | 1237 | 0 | 922 |
| 34 | 720 | 240 | 0 | 347 | 834 | 560 | 0 | 1595 | 537 |
| 35 | 36 | 101 | 909 | 1905 | 3219 | 400 | 1912 | 646 | 1147 |
| 36 | 36 | 327 | 900 | 0 | 1860 | 1112 | 0 | 50 | 536 |
| 37 | 139 | 950 | 85 | 2594 | 3094 | 3344 | 1097 | 913 | 1527 |
| 38 | 23 | 11 | 234 | 486 | 135 | 8 | 0 | 46 | 118 |
| 39 | 75 | 500 | 675 | 875 | 2345 | 783 | 0 | 250 | 688 |
| 40 | 116 | 234 | 0 | 400 | 3218 | 794 | 0 | 152 | 614 |
| 41 | 290 | 2040 | 3500 | 1440 | 3467 | 1127 | 713 | 490 | 1633 |
| 42 | 52 | 0 | 630 | 1180 | 0 | 651 | 3481 | 402 | 800 |
| 43 | 841 | 1188 | 3284 | 700 | 0 | 0 | 3079 | 780 | 1234 |
| 44 | 350 | 300 | 481 | 2000 | 0 | 0 | 0 | 459 | 449 |
| 45 | 15 | 0 | 720 | 120 | 1800 | 76 | 341 | 96 | 396 |
| 46 | 166 | 2345 | 769 | 1115 | 0 | 0 | 0 | 2300 | 837 |

Construiremos diagramas de cajón con bigotes a partir de estos datos, de modo de poder comparar los gastos en los diferentes rubros.

Se muestra en verde el diagrama de cajón correspondiente a los promedios por empresa.



Podemos observar que, en general, en todos los rubros hay bastante **asimetría** en la forma como se distribuyen los gastos, y que la mayoría de los datos se concentran hacia valores bajos, con algunos pocos valores altos.

En todos los rubros, excepto en Mantención, hay **valores extremos**, todos grandes.

Si tratamos de pesquisar estos valores extremos en la tabla de datos, veremos que son gastos extraordinariamente grandes y que, en general, se trata de un caso distinto por cada empresa.

Sólo hay tres empresas con gastos extremos en dos rubros. Una de ellas es la identificada con el número 12, que es responsable del único valor extremo que aparece en el promedio.

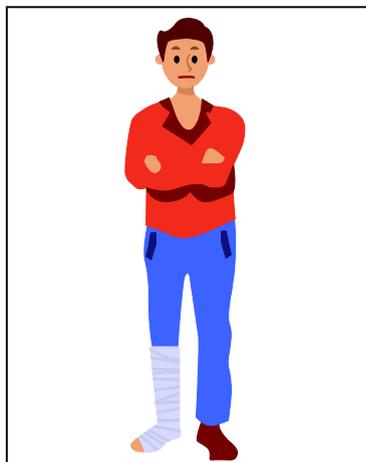
EJEMPLO 31

Accidentes laborales.

Se tiene los siguientes datos que corresponden al número de accidentes laborales en el mes de enero de 2021, en cada región, por hombres, mujeres y totales.

Estos datos se extrajeron del sitio web del Instituto Nacional de Estadísticas (INE)

Se agregaron las poblaciones de las regiones, de Hombre, Mujeres y Totales, tomadas del Censo 2017.



Las variables registradas son:

Región - el nombre de cada región.

Num.Región - su número.

acc.Hom - número de Hombres afectados por accidentes de trabajo.

acc.Muj - número de Mujeres afectados por accidentes de trabajo.

acc.tot - número Total de afectados por accidentes de trabajo.

pob.Hom - población de Hombres.

pob.Muj - población de Mujeres.

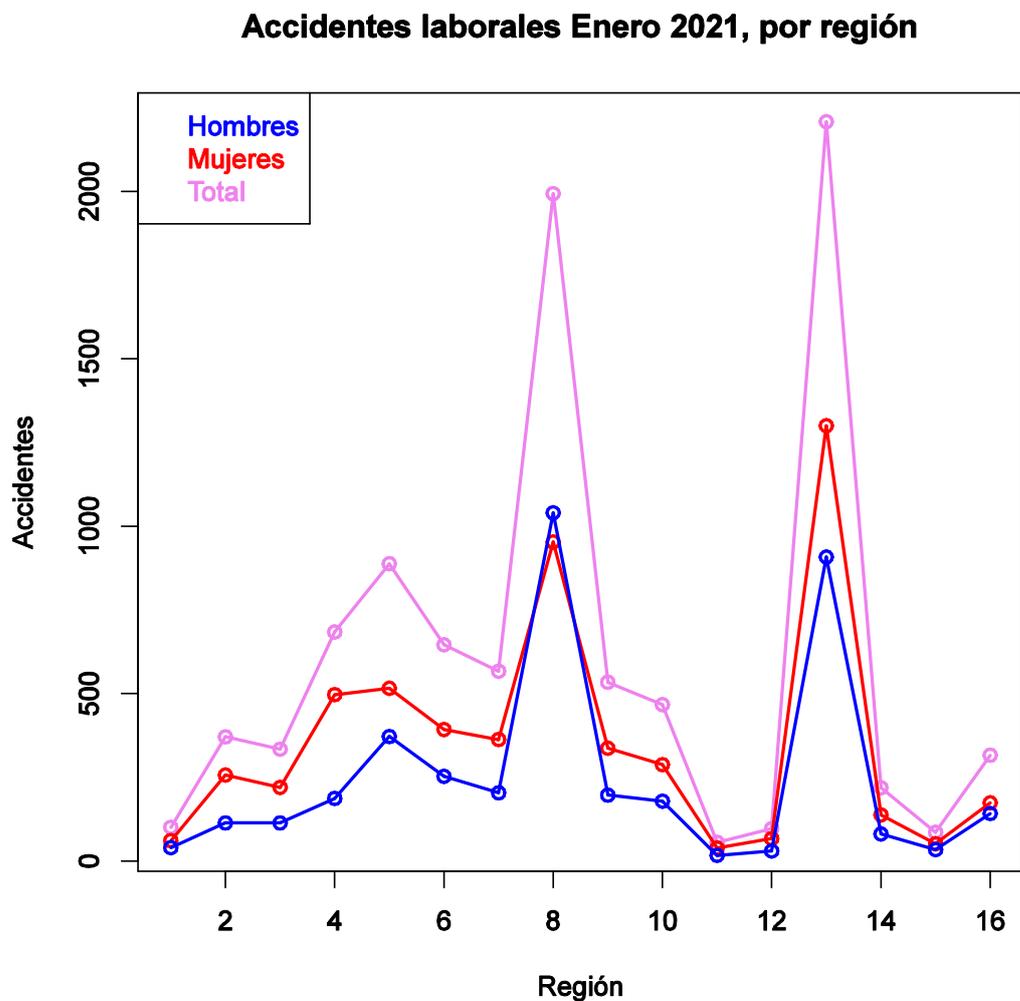
pob.tot - población Total.

Los datos son los siguientes:

| Region | Num. region | acc.Hom | acc.Muj | acc.tot | pob.Hom | pob.Muj | pob.tot |
|--------------------|-------------|---------|---------|---------|---------|---------|---------|
| Tarapacá | 1 | 40 | 61 | 101 | 167793 | 162765 | 330558 |
| Antofagasta | 2 | 114 | 257 | 371 | 315014 | 292520 | 607534 |
| Atacama | 3 | 114 | 220 | 334 | 144420 | 141748 | 286168 |
| Coquimbo | 4 | 187 | 497 | 684 | 368774 | 388812 | 757586 |
| Valparaíso | 5 | 372 | 516 | 888 | 880215 | 935687 | 1815902 |
| O'Higgins | 6 | 253 | 393 | 646 | 453710 | 460845 | 914555 |
| Maule | 7 | 204 | 363 | 567 | 511624 | 533326 | 1044950 |
| Biobio | 8 | 1040 | 953 | 1993 | 750730 | 806075 | 1556805 |
| La Araucanía | 9 | 197 | 337 | 534 | 465131 | 492093 | 957224 |
| Los Lagos | 10 | 179 | 288 | 467 | 409400 | 419308 | 828708 |
| Aysén | 11 | 17 | 39 | 56 | 53647 | 49511 | 103158 |
| Magallanes | 12 | 30 | 67 | 97 | 85249 | 81284 | 166533 |
| Metropolitana | 13 | 908 | 1300 | 2208 | 3462267 | 3650541 | 7112808 |
| Los Ríos | 14 | 81 | 138 | 219 | 188847 | 195990 | 384837 |
| Arica y Parinacota | 15 | 34 | 52 | 86 | 112581 | 113487 | 226068 |
| Ñuble | 16 | 142 | 174 | 316 | 232587 | 248022 | 480609 |

Haremos un gráfico de los accidentes versus la región, éstas ordenadas por número, separando en tres variables: accidentes de Mujeres, de Hombres y Total.

Uniremos los puntos correspondientes a una misma variable por líneas con el objeto de visualizar mejor cada variable por separado.



Podemos observar que las tres líneas quebradas siguen el mismo patrón. Sin embargo, la de las Mujeres está más arriba en todos los puntos, salvo en la región 8 (Biobío), en que es ligeramente inferior.

También vemos que las Regiones 8 (Biobío) y 13 (Metropolitana), tienen notoriamente más accidentes que el resto de las regiones.

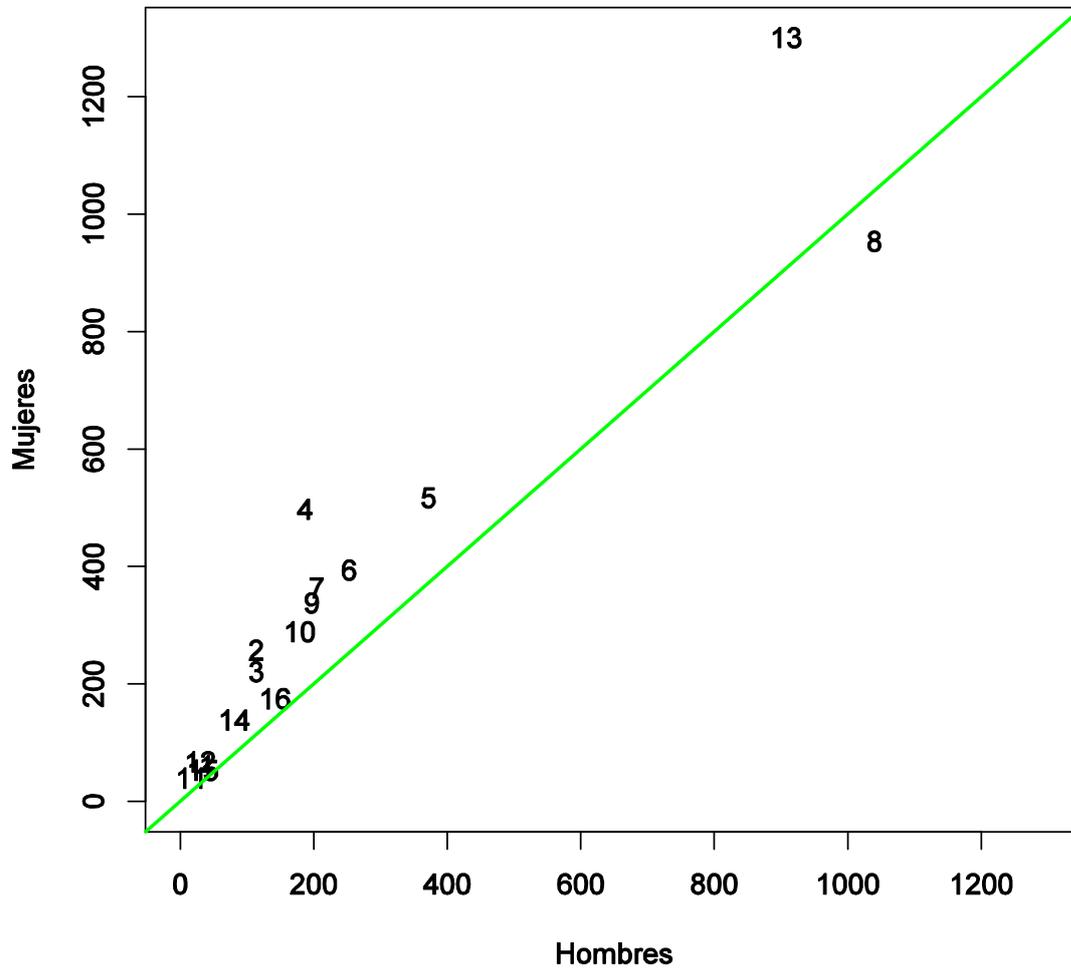
En el caso de la región 13 es claro que se debe a que es una Región notablemente más poblada que las demás.

Sin embargo, la Región 5 (Valparaíso) tiene una mayor población que la 8, pero tiene menos accidentes. Aunque sí tiene más que las restantes Regiones.

A continuación, haremos un gráfico de dispersión del total de accidentados Mujeres versus el total de accidentados Hombres, identificando cada punto con el número de la Región.

Se trazó una línea diagonal verde, que representaría la igualdad entre accidentes de Hombres y Mujeres.

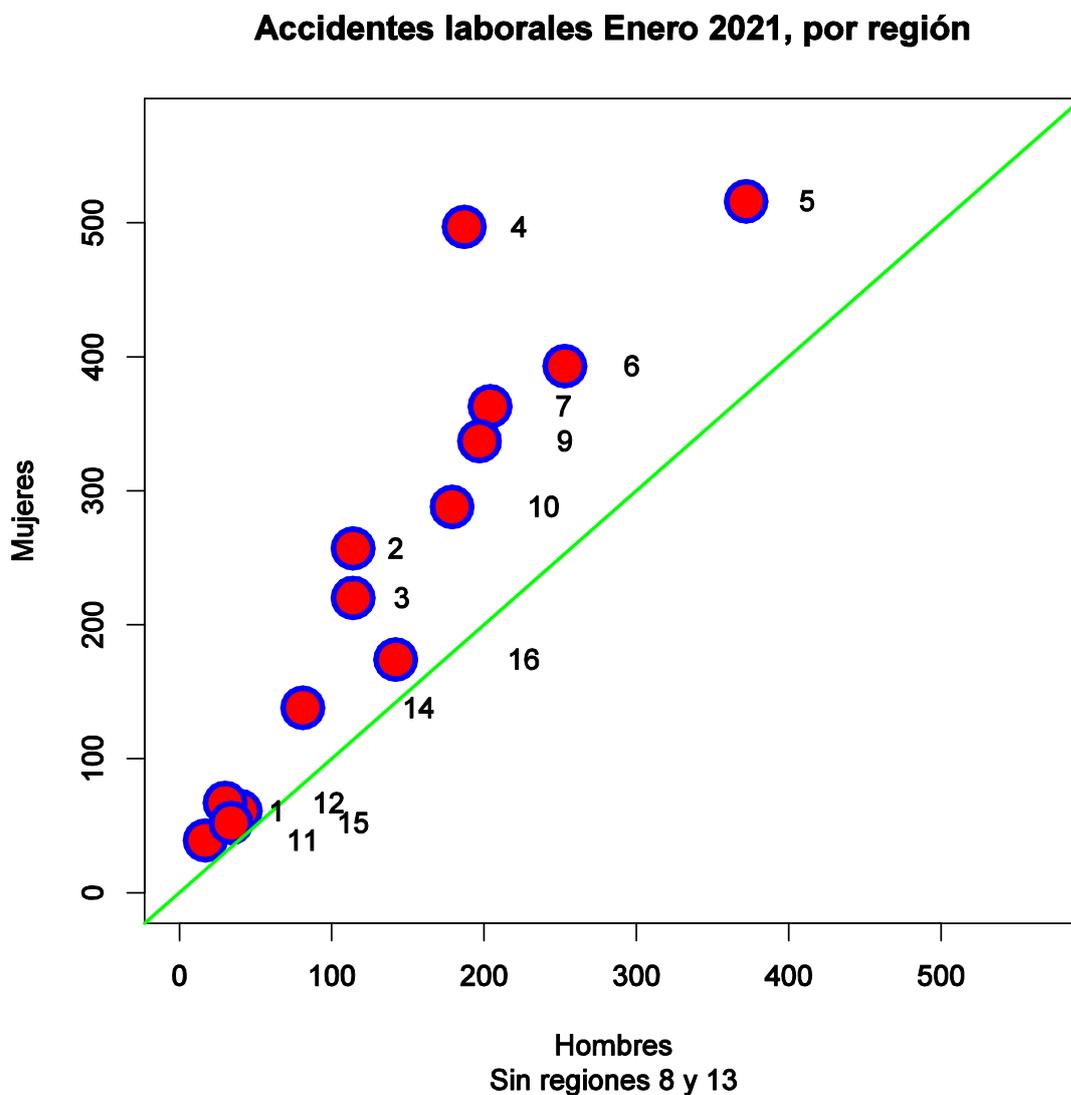
Accidentes laborales Enero 2021, por región



Aquí se observa claramente que los puntos aparecen sobre la recta diagonal, lo que ratifica el hecho que el número de accidentes de Mujeres es superior al de los Hombres, salvo en el caso de la Región 8.

Además, el gráfico destaca el hecho que las Regiones 8 y 13 tienen números mucho más grandes de accidentes.

Con el objeto de observar con más claridad el comportamiento de las demás regiones, haremos el mismo gráfico de dispersión, pero sin incluir las Regiones 8 y 13, de modo de agrandar la escala.



En este gráfico vemos que, entre estas, la Región 5 es la de más accidentados, y la 4 es la que tiene notoriamente más accidentadas Mujeres que Hombres.

Las con menos accidentados son las Regiones 1 (Tarpacá), 11 (Aysén), la de menor población, 12 (Magallanes) y 15 (Arica y Parinacota).

Interesa visualizar los accidentados estandarizados, es decir, como si todas las Regiones tuvieran la misma población.

Para eso definimos tres Tasas:

Accidentados Hombres por cada 100.000 habitantes Hombres.

Accidentadas Mujeres por cada 100.000 Mujeres.

Accidentados totales por cada 100.000 habitantes (Hombres y Mujeres).

El cálculo de cada tasa se hace dividiendo el valor de accidentados por la población respectiva y multiplicando por 100.000. Lo redondeamos a un decimal.

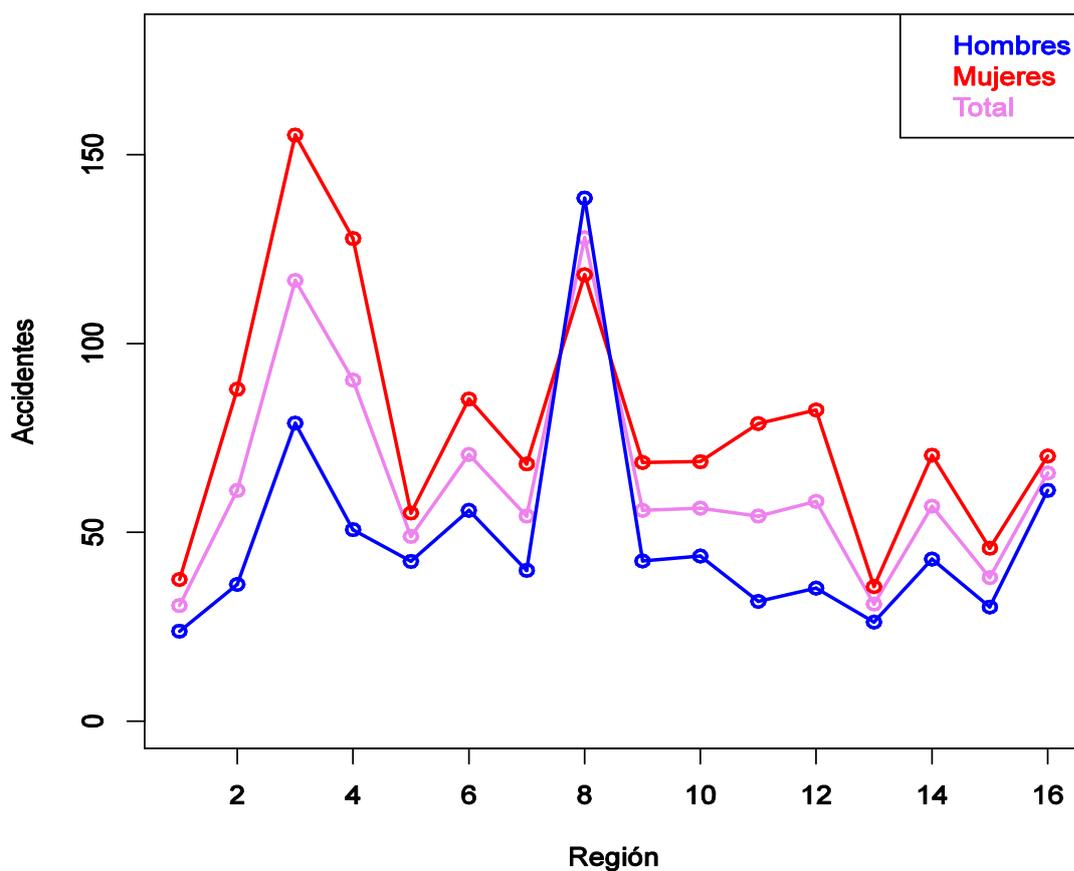
Los valores obtenidos son los siguientes:

| Num.región | tasa.Hom | tasa.Muj | tasa.tot |
|------------|----------|----------|----------|
| 1 | 23.8 | 37.5 | 30.6 |
| 2 | 36.2 | 87.9 | 61.1 |
| 3 | 78.9 | 155.2 | 116.7 |
| 4 | 50.7 | 127.8 | 90.3 |
| 5 | 42.3 | 55.1 | 48.9 |
| 6 | 55.8 | 85.3 | 70.6 |
| 7 | 39.9 | 68.1 | 54.3 |
| 8 | 138.5 | 118.2 | 128.0 |
| 9 | 42.4 | 68.5 | 55.8 |
| 10 | 43.7 | 68.7 | 56.4 |
| 11 | 31.7 | 78.8 | 54.3 |
| 12 | 35.2 | 82.4 | 58.2 |

| Num.región | tasa.Hom | tasa.Muj | tasa.tot |
|------------|----------|----------|----------|
| 13 | 26.2 | 35.6 | 31.0 |
| 14 | 42.9 | 70.4 | 56.9 |
| 15 | 30.2 | 45.8 | 38.0 |
| 16 | 61.1 | 70.2 | 65.7 |

Con estos datos construimos un gráfico de Tasa de accidentes versus la región, separados en Mujeres, Hombres y Total. Los puntos de cada variable unidos por rectas.

Tasa de accidentes Enero 2021, por región, por cada 100.000

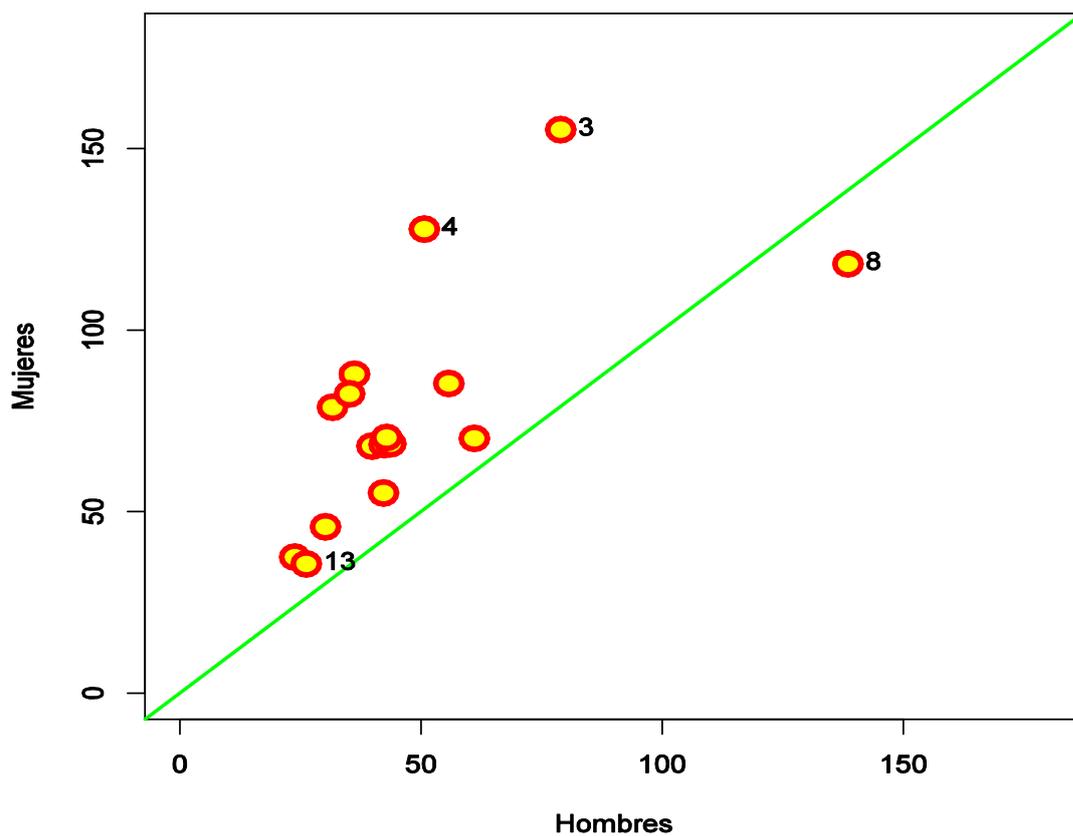


Podemos ver que ahora las tasas de accidentes son mayores para las regiones 3 (Atacama), 4 (Coquimbo) y 8 (Biobío).

Pero también observamos que, a diferencia de los Totales, las Tasas son mayores para las Mujeres que para los Hombres y que para los Totales, en todas las Regiones excepto la 8.

Finalmente, con estos datos construimos un gráfico de dispersión de la tasa de accidentadas Mujeres versus la tasa de accidentados Hombres. Se incluye las regiones 8 y 13 que se habían eliminado.

Accidentes laborales Enero 2021, por región, por cada 100.000



En este gráfico se puede ver que cambia la posición relativa de los puntos.

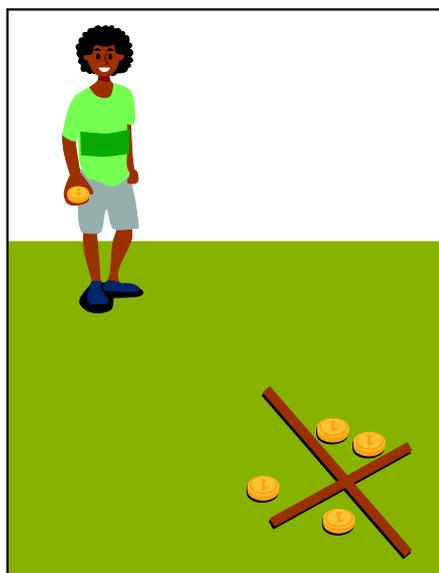
En efecto, podemos ver que la Región 13 (Metropolitana), que era la de mayor cantidad de accidentes, ahora pasó a ser la de menor Tasa, accidentados por 100.000 habitantes, similar a la región 1 (Tarapacá).

Mientras que la Región 8 se mantiene teniendo un valor más grande, en los accidentados Hombres.

Junto a las Regiones 3 (Atacama) y 4 (Coquimbo), que tienen tasas altas en el caso de Mujeres.

ACTIVIDAD PRÁCTICA 3

Traza dos líneas rectas perpendiculares en el suelo. Párate a unos tres a cuatro metros detrás, en la dirección de una de las líneas perpendiculares.



Lanza monedas tratando de apuntarle el punto en que se cruzan las dos líneas.

Mide y registra la distancia, en centímetros, desde donde cayó la moneda hasta cada una de las dos líneas.

Esto lo repites varias veces.

Pueden participar todos los alumnos del curso, divididos en **equipos**, de modo de juntar una cantidad grande de pares de distancias.

Con estos datos puedes construir un gráfico de dispersión, que te permitirá determinar en qué dimensión hay más error, la dirección del lanzamiento o la dirección perpendicular.

En el gráfico, separa los puntos según el equipo participante, usando diferentes colores.

Obtén algunas conclusiones.

EJEMPLO 32

Productos agrícolas.

Los datos siguientes corresponden a producción de 21 productos agrícolas en los períodos 2019-2020 y 2020-2021, en quintales (1 quintal=100 kilos).



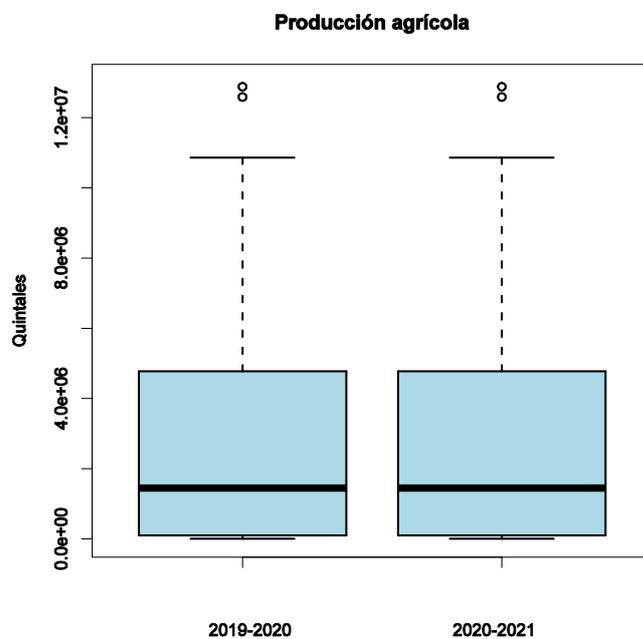
En la tabla aparece el cultivo, la categoría a la que pertenece y la subcategoría.

Nuestro objetivo es comparar la producción en los dos períodos.

La fuente de los datos es el Instituto Nacional de estadísticas, INE.

| num | Cultivo | prod19-20 | prod20-21 | categoría | sub-categoría | ncat |
|-----|-------------------------|-----------|-----------|--------------|---------------|------|
| 1 | Trigo Harinero | 10861401 | 12033828 | cereales | trigo | 1 |
| 2 | Trigo Candeal | 1448483 | 1502251 | cereales | trigo | 1 |
| 3 | Cebada Cervecera | 1586470 | 1164548 | cereales | cebada | 1 |
| 4 | Cebada Forrajera | 345189 | 410764 | cereales | cebada | 1 |
| 5 | Avena | 4773956 | 5252446 | cereales | avena | 1 |
| 6 | Maíz Consumo | 5658838 | 7719603 | cereales | maiz | 1 |
| 7 | Maíz Semilla | 271043 | 218615 | cereales | maiz | 1 |
| 8 | Arroz | 1696965 | 1460851 | cereales | arroz | 1 |
| 9 | Triticale | 928634 | 551828 | cereales | tricale | 1 |
| 10 | Poroto | 91774 | 174910 | leguminosas | porotp | 2 |
| 11 | Lenteja | 5850 | 5717 | leguminosas | lenteja | 2 |
| 12 | Garbanzo | 1853 | 3116 | leguminosas | garbanzo | 2 |
| 13 | Papa | 12881536 | 9945078 | papas | papas | 3 |
| 14 | Raps | 1535334 | 1405858 | industriales | raps | 4 |
| 15 | Maravilla | 34097 | 21433 | industriales | maravilla | 4 |
| 16 | Lupino Amargo | 98776 | 160964 | industriales | lupino | 4 |
| 17 | Otros Lupinos | 200870 | 209531 | industriales | lupino | 4 |
| 18 | Remolacha azucarera | 12590481 | 7462724 | industriales | remolacha | 4 |
| 19 | Tabaco | 64389. | 39248 | industriales | tabaco | 4 |
| 20 | Tomate Industrial | 5234810 | 6768235 | industriales | tomate | 4 |
| 21 | Achicoria Industrial | 1939388 | 2674475 | industriales | achicoria | 4 |

Primero que nada, haremos dos diagramas de cajón con bigotes de los dos períodos.



Podemos observar que, en general, se ven parecidas las producciones en ambos períodos.

También se observa una fuerte asimetría superior, con dos valores extremos.

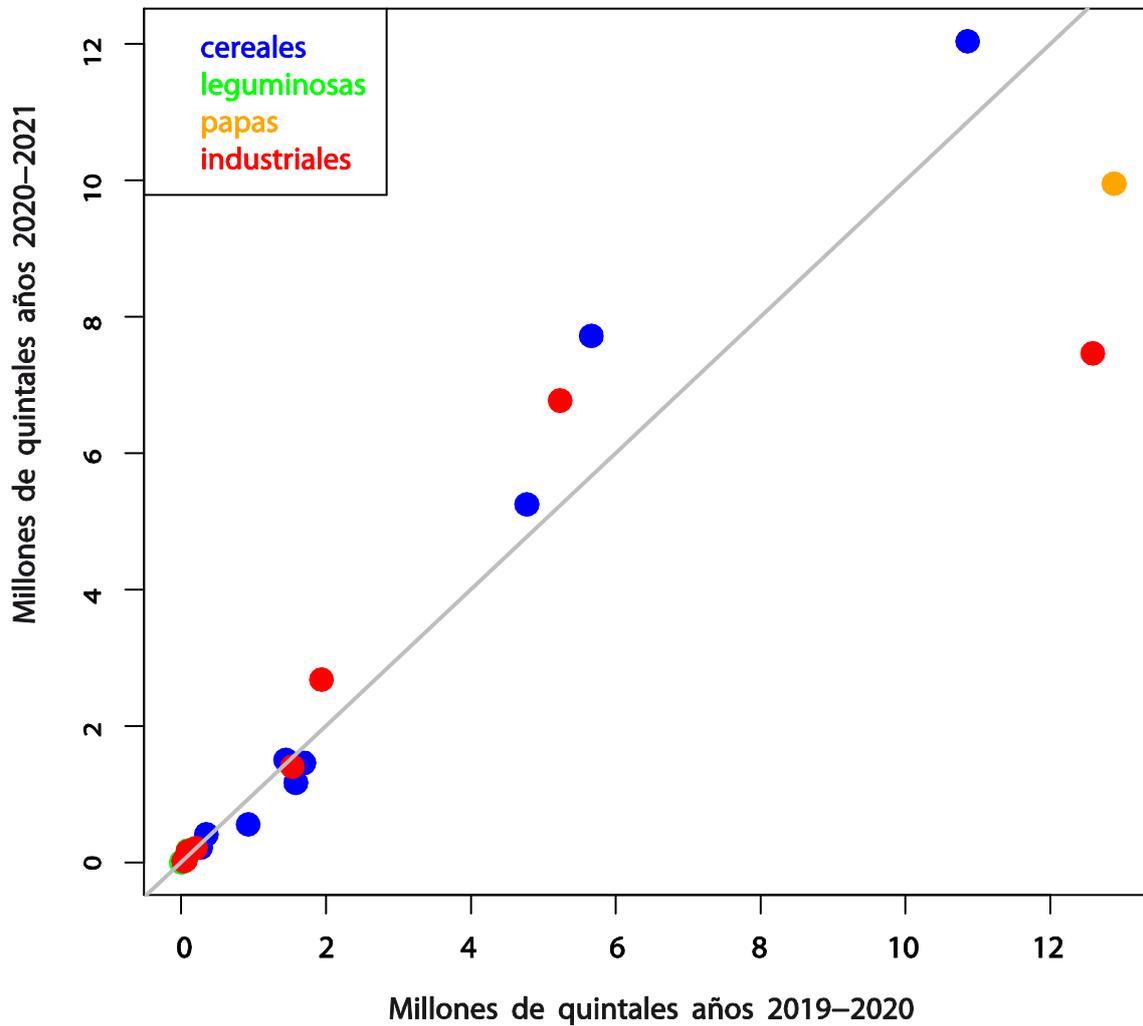
Estos son la Papa y la Remolacha Azucarera, ambas exceden los 12 millones de quintales.

Ahora haremos un diagrama de dispersión. Pondremos la producción en 2019-2020 en el eje horizontal y la producción 2020-2021 en el eje vertical.

Esto nos permitirá comparar los dos períodos.

Hay cuatro categorías: Cereales, Leguminosas, Papas e Industriales. Los puntos correspondientes a cada una los representaremos en colores diferentes.

Producción agrícola



Hemos trazado una línea diagonal que representa los puntos en que ambas variables toman los mismos valores.

Si un punto está sobre la diagonal significa que hubo un aumento en la producción 2020-2021 respecto del período anterior.

Si el punto está debajo de la diagonal, hubo una disminución.

Hay que aclarar que todo lo que se ve en un gráfico, también se puede deducir directamente de los datos.

¿Cuál es la ventaja del gráfico? Que se ve todo con mucho mayor claridad que de una tabla de datos. El gráfico da información menos precisa, pero más fácil de entender.

El problema que tenemos es que nos encontramos con que hay algunos puntos dispersos, pero hay una gran concentración de puntos en torno a los valores bajos, que no permiten ver el detalle.

Entonces haremos lo siguiente: Dividiremos los datos en tres grupos, de acuerdo a la producción en el período 2019-2020:

El grupo de Baja Producción, con los 7 productos que presentan producción más baja en el período 2019-2020.

El grupo de Producción Media, los siguientes 7 productos.

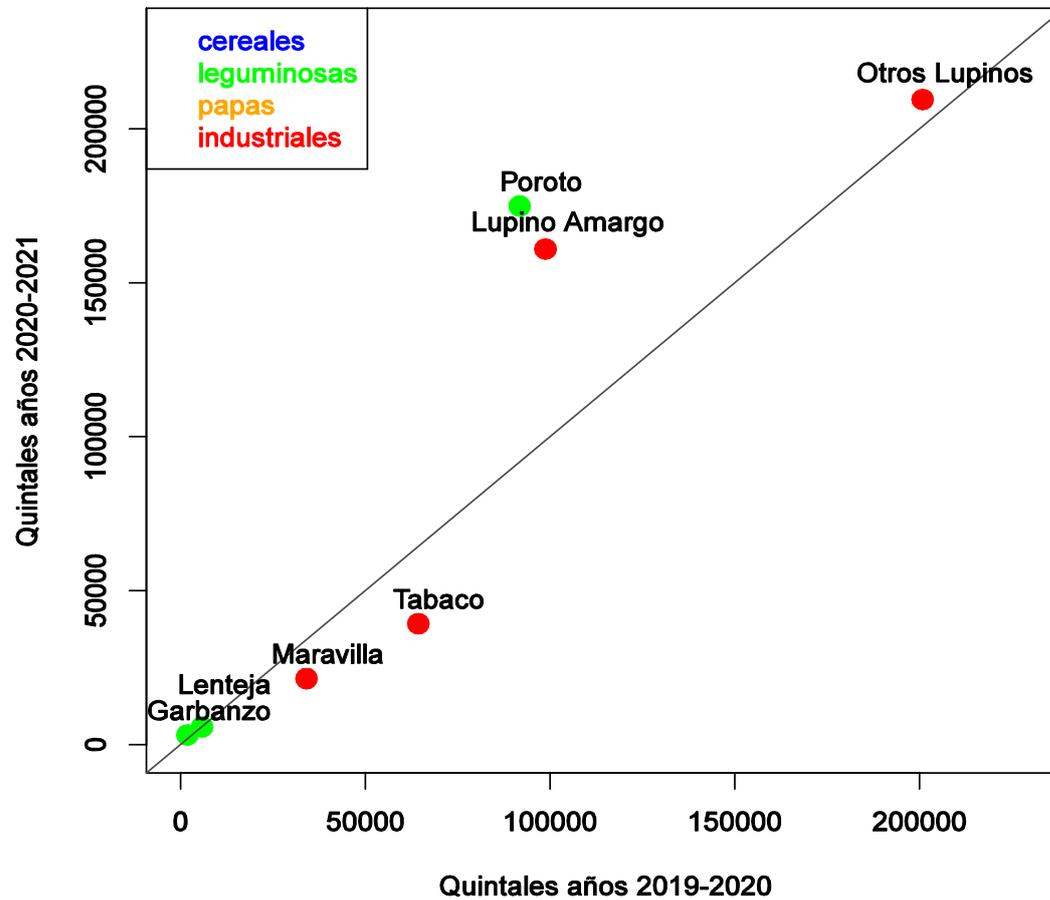
El grupo de Alta Producción, los 7 con la producción más alta en 2019-2020.

Y representaremos cada grupo en un gráfico separado.

Esto es como hacerle un zoom al gráfico anterior.

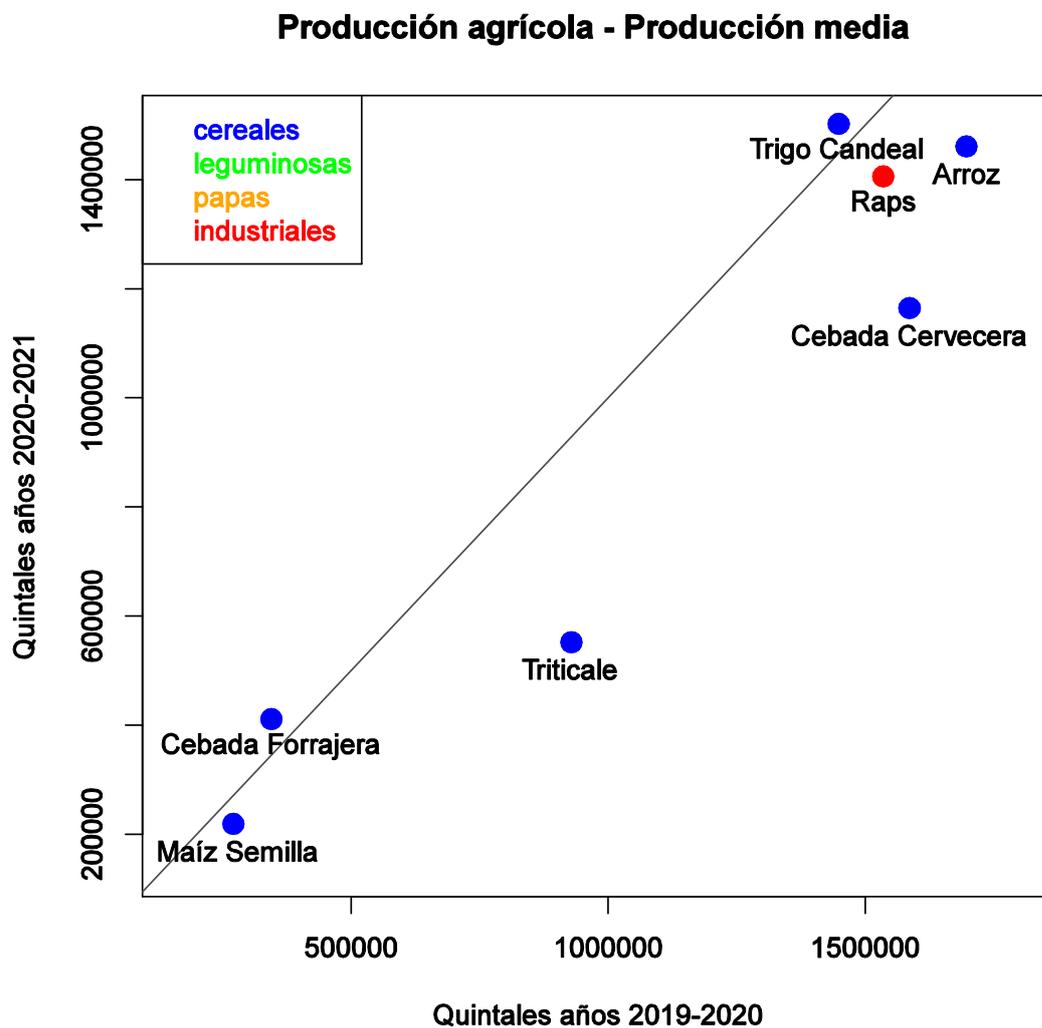
Los resultados son los siguientes, partiendo por Baja Producción, e individualizando cada producto:

Producción agrícola - Baja producción



Se ven las tres Leguminosas, en verde, y algunos productos industriales, en rojo.

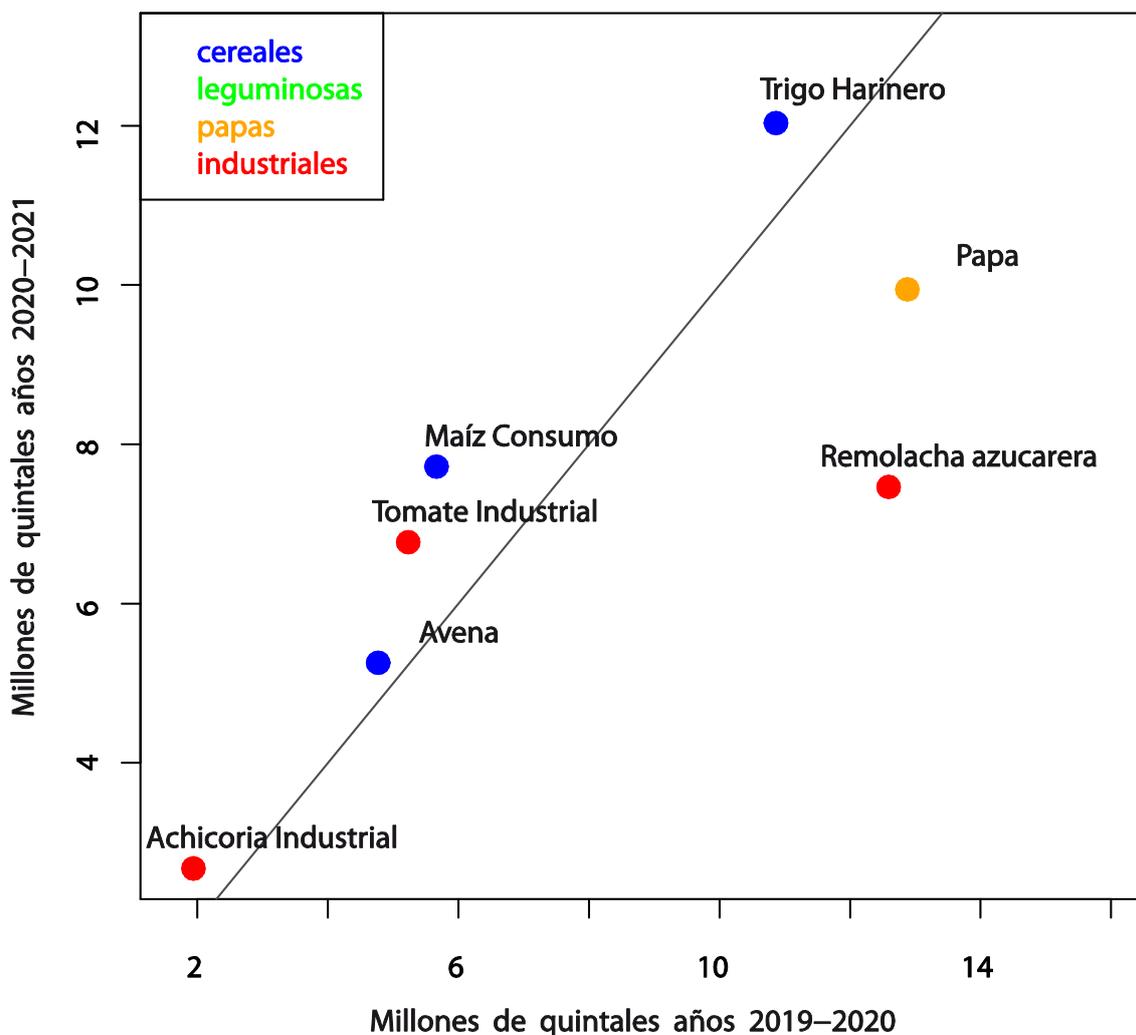
Están cerca de lo línea diagonal, excepto Poroto y Lupino Amargo, que muestran un aumento en su producción.



En la Producción Media aparece un producto industrial, el Raps. Todos los demás son Cereales, representados en azul.

Algunos de ellos, Cebada Cervecera, Arroz y Triticale con una disminución en su producción en 2020-2021 respecto del período anterior. Raps también, pero con una disminución menor.

Producción agrícola – Alta producción



En este gráfico, de Alta Producción, aparece la Papa y la Remolacha Azucarera, con disminuciones en su producción. Algunos de los demás productos tienen aumentos menores en la producción.

Si se desea hacer comparaciones entre los tres gráficos, se debe tener en cuenta que tienen escalas diferentes.

Las marcas del eje vertical del gráfico de baja producción van de 0 a 200.000 quintales.

Las de Producción media, de 200.000 a 1.400.000 quintales.

Las de Alta producción van de 4 millones a 12 millones de quintales.

Por lo tanto, una distancia de un centímetro en uno de los tres gráficos no corresponde a lo mismo que un centímetro en otro.

EJERCICIOS

22) La tabla de datos siguiente muestra la producción de leche en la Región de Los Lagos, en el cuarto trimestre de los años 2018, 2019 y 2020.



Las variables son:

A - año

M - mes

NProc - número de productores

VolTot - volumen total producido (miles de litros Mlt)

Propia - producción propia (Mlt)

Adquirida - producción adquirida (Mlt)

NPCompran - cantidad de plantas que compran leche

NProv - número de proveedores de leche.

| Año | Mes | NProc | VolTot | Propia | Adquirida | NPCompran | NProv |
|------|------------|-------|--------|--------|-----------|-----------|-------|
| 2018 | Enero | 18 | 4830 | 150 | 4680 | 11 | 141 |
| 2018 | Febrero | 18 | 3706 | 135 | 3570 | 11 | 139 |
| 2018 | Marzo | 18 | 3743 | 135 | 3608 | 11 | 133 |
| 2018 | Abril | 16 | 3414 | 109 | 3305 | 10 | 130 |
| 2018 | Mayo | 16 | 3210 | 103 | 3107 | 10 | 132 |
| 2018 | Junio | 16 | 2891 | 100 | 2791 | 10 | 125 |
| 2018 | Julio | 17 | 2934 | 81 | 2853 | 11 | 127 |
| 2018 | Agosto | 17 | 3582 | 91 | 3491 | 12 | 130 |
| 2018 | Septiembre | 17 | 3904 | 87 | 3817 | 12 | 129 |
| 2018 | Octubre | 19 | 4856 | 134 | 4722 | 11 | 134 |
| 2018 | Noviembre | 19 | 5356 | 124 | 5232 | 11 | 135 |
| 2018 | Diciembre | 19 | 5130 | 113 | 5017 | 12 | 131 |
| 2019 | Enero | 17 | 4751 | 152 | 4598 | 11 | 134 |
| 2019 | Febrero | 17 | 4084 | 141 | 3943 | 11 | 139 |
| 2019 | Marzo | 17 | 3710 | 125 | 3585 | 12 | 144 |
| 2019 | Abril | 16 | 2926 | 116 | 2810 | 11 | 129 |
| 2019 | Mayo | 16 | 3025 | 106 | 2919 | 11 | 127 |
| 2019 | Junio | 16 | 2773 | 109 | 2664 | 11 | 120 |
| 2019 | Julio | 17 | 2603 | 80 | 2523 | 11 | 112 |
| 2019 | Agosto | 17 | 2846 | 63 | 2782 | 11 | 105 |
| 2019 | Septiembre | 17 | 3536 | 64 | 3472 | 12 | 105 |
| 2019 | Octubre | 16 | 4359 | 125 | 4234 | 11 | 108 |
| 2019 | Noviembre | 16 | 4747 | 124 | 4623 | 11 | 114 |
| 2019 | Diciembre | 16 | 4599 | 130 | 4469 | 11 | 111 |

| Año | Mes | NProc | VolTot | Propia | Adquirida | NPCompran | NProv |
|------|------------|-------|--------|--------|-----------|-----------|-------|
| 2020 | Enero | 16 | 4220 | 124 | 4096 | 11 | 111 |
| 2020 | Febrero | 16 | 3764 | 115 | 3649 | 11 | 111 |
| 2020 | Marzo | 16 | 3205 | 107 | 3098 | 11 | 109 |
| 2020 | Abril | 15 | 2518 | 71 | 2448 | 10 | 109 |
| 2020 | Mayo | 15 | 2772 | 69 | 2703 | 10 | 109 |
| 2020 | Junio | 15 | 2389 | 61 | 2329 | 10 | 107 |
| 2020 | Julio | 15 | 2317 | 54 | 2263 | 9 | 106 |
| 2020 | Agosto | 15 | 2720 | 55 | 2665 | 10 | 113 |
| 2020 | Septiembre | 15 | 3491 | 68 | 3423 | 10 | 118 |
| 2020 | Octubre | 15 | 4423 | 101 | 4322 | 10 | 114 |
| 2020 | Noviembre | 15 | 4694 | 103 | 4591 | 10 | 113 |
| 2020 | Diciembre | 15 | 4392 | 70 | 4322 | 10 | 118 |

a) Haz un análisis similar a lo del Ejemplo 31, de la producción agrícola, relacionando las variables **Número de productores** y **Volumen total producido**. De cada gráfico obtén conclusiones.

b) Lo mismo que en a), pero con las variables **Producción propia** y **Producción adquirida**.

c) Lo mismo que en a), pero con las variables **Cantidad de plantas que compran leche** y **Número de proveedores de leche**.

APÉNDICE 1 - Uso de Microsoft Excel

Las planillas Excel de los ejemplos las puedes encontrar en el sitio web del autor

www.aprendoestadistica.cl

o bien puedes escanear este QR.



Para usar las funciones estadísticas de Excel se ocupa insertar función, que se muestra con el símbolo f_x

Presionando f_x aparecerá un submenú con la lista de funciones disponibles.

Para gráficos se va a

Insertar

En el submenú **Gráficos** se elige el gráfico a usar.

Para procedimientos estadísticos más complejos se debe recurrir a

Datos

Análisis de Datos. Al presionarlo aparecerá un submenú con la lista de procedimientos disponibles.

Podría ser que **Análisis de Datos** no esté habilitado. En ese caso se debe hacer lo siguiente, una sola vez:

Archivo

Opciones

Complementos

Complementos de Excel

Análisis de datos

Con eso queda habilitada la opción **Análisis de Datos** en **Datos** todas las veces que ingresemos a Excel.

EJEMPLO 12 - Egresados instituto profesional

Seleccionar las dos columnas de datos, sin incluir los totales, pero sí incluyendo los encabezados superiores y los de la izquierda.

Luego posicionarse en INSERTAR, y de ahí seleccionar el tipo de gráfico que se quiere.

Aparecen dibujados diferentes tipos de gráfico.

En este caso elegir INSERTAR GRAFICO COLUMNAS O DE BARRAS.

De entre los que aparecen, seleccionar COLUMNA EN 2D. Automáticamente construirá el gráfico requerido, a excepción del título.

Eso permitirá escribir el título que uno quiere.

Para personalizar el título principal, hacer doble click en el título y escribir el título que corresponde.

Para personalizar el título de un eje, hacer doble click en el título y escribir el título que corresponde.

Para personalizar la escala de un eje, hacer doble click en la escala correspondiente. Aparece un menú "dar formato al eje". Seleccionar la última opción que permite personalizar la escala.

EJEMPLO 13 - Puntajes examen postulación

Como en el Ejemplo 12, pero seleccionar sólo la fila de frecuencias de la tabla de frecuencias.

Lo demás es igual que en el Ejemplo 12.

EJEMPLO 24 y 26 - Notas de Ciencias Sociales (varianza).

Está hecho de dos formas.

La primera consiste en sumar los valores y sumar sus cuadrados, usando las funciones **suma()** y **sumacuad()** de Excel. Luego se aplica la fórmula para calcular la varianza. Se mide en puntos al cuadrado.

La desviación estándar se obtiene extrayendo la raíz cuadrada de la varianza, con la función **raiz()**. Se mide en puntos.

El coeficiente de variación se obtiene dividiendo la desviación estándar por el promedio. No tiene unidad de medida, es un número abstracto.

La segunda forma de obtener estas medidas es usando directamente las funciones **var()** y **desvest()** de Excel.

El coeficiente de variación se obtiene dividiendo la desviación estándar por el promedio.

EJEMPLO 28 - Experiencia y sueldo de funcionarios.

Seleccionar las columnas que contienen los años de experiencia y el sueldo.

Ir a INSERTAR, seleccionar el gráfico de dispersión.

Para personalizar los títulos y escalas, seguir el procedimiento descrito en el Ejemplo 12.

EJEMPLO 29 - Generación de energía eléctrica.

Seleccionar las dos columnas de datos.

Ir a INSERTAR

Para el primer gráfico seleccionar GRÁFICO DE DISPERSIÓN

Para el segundo gráfico seleccionar GRÁFICO DE COLUMNAS O BARRAS

Elegir el gráfico adecuado.

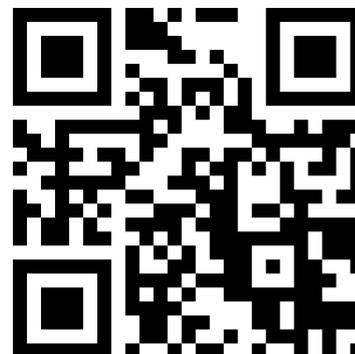
Para personalizar los títulos y escalas, seguir el procedimiento descrito en el Ejemplo 12.

APÉNDICE 2 - Uso de R

Los programas R de los ejemplos los puedes encontrar en el sitio web del autor

www.aprendoestadistica.cl

o bien puedes escanear este QR.



R es dos cosas a la vez: un lenguaje de programación y un paquete estadístico utilizado ampliamente por los estadísticos del mundo.

Nosotros lo usaremos fundamentalmente como paquete estadístico.

Es de código abierto y licencia libre.

Para instalarlo se debe ingresar al sitio www.r-project.org

Presionar **Download R**

Se pedirá elegir una de una lista de URL. Puede ser cualquiera, pero se recomienda una de Chile.

De ahí habrá que elegir una de tres opciones:

Download R for Linux (Debian, Fedora/Redhat, Ubuntu)

Download R for macOS

Download R for Windows

Luego presionar **Install R for the first time** y finalmente **Download R** (versión) for (**Linux, Mac** o **Windows**)

En breve tiempo estará disponible el programa de instalación, que se deberá correr y seguir las instrucciones. Todo el proceso no tarda más de 5 minutos.

Al correr R aparecerá la consola de R (**R Console**). En esta consola aparecerán los resultados. También se pueden ingresar comandos, que se ejecutarán con sólo presionar Enter. Entregará el resultado, pero el comando no será posible correrlo de nuevo, sin ingresarlo nuevamente.

Para poder conservar los comandos ingresados, se ingresa a

Archivo

Nuevo Script

Aparecerá un cuadro **Sin nombre - Editor R**. En él se podrán escribir comandos, editarlos, y guardarlo como archivo R para recuperarlo nuevamente en otra sesión de R. Se denomina un **Script**. Para recuperarlo:

Archivo

Abrir Script

Para ejecutar el script o parte de él:

Seleccionar lo que se quiere ejecutar e ir a:

Editar

Correr línea o seleccionar

Hagamos este sencillo ejercicio (lo que aparece después de # es un comentario no ejecutable):

Abrir un script nuevo. Ingresar:

```
M<-30 # define la constante M
v<-c(12,34,78,4,15) # define el vector v
mean(v) # promedio de los elementos de v
M *v # multiplica los elementos de v por M.
b<-M-v # sustrae los elementos de vector v a la constante M
# y los guarda en b para cálculos posteriores
b # muestra el valor de b
```

Para ejecutarlo, se puede hacer por partes (respetando el orden de los comandos) o todo de una vez.

Tener en cuenta:

El programa distingue entre minúsculas y mayúsculas. No usar acentos ni la letra ñ.

Las constantes que se ingresan o que se calculan se mantienen en memoria mientras no se cierre el programa R.

Para ayuda en un comando, correr **help(comando)** y se desplegará la página correspondiente del manual.

A continuación, detallaremos el uso de R en algunos de los Ejemplos, para que te inicies en el conocimiento de este sistema computacional:

EJEMPLO 11 - ALTURAS DE ESTUDIANTES

Ingresar los datos como un vector:

```
alturas<-c(146, 175, 147, 143, 170, 172, 177, 162, 160, 164, 185, 151,180, 161,  
152, 171, 182, 163, 181, 169, 148, 184, 166, 157, 176, 156, 149, 178, 153, 168)
```

```
mu<-mean(alturas) # promedio de todas las alturas
```

```
mu # ver el promedio de todos
```

```
muestra1<-sample(alturas,10,replace=TRUE) # obtener muestra al azar tamaño 10  
con reposicion
```

```
muestra1 # ver valores
```

```
mean(muestra1) # calcular promedio de la muestra
```

obtener otras muestras al azar:

```
muestra2<-sample(alturas,10,replace=FALSE) # obtener otra muestra tamaño 10 sin  
reposicion
```

```
muestra2
```

```
mean(muestra2)
```

```
muestra3<-sample(alturas,10,replace=FALSE) # obtener otra muestra tamaño 10 sin  
reposicion
```

```
muestra3
```

```
mean(muestra3)
```

```
muestra4<-sample(alturas,10,replace=FALSE) # obtener otra muestra tamaño 10 sin  
reposicion
```

```
muestra4
```

```
mean(muestra4)
```

cada vez que se corre lo anterior, las muestras obtenidas seran distintas.

#####

EJEMPLO 16 - NOTAS CIENCIAS SOCIALES

```
notas<-
c(5.2,4.6,6.2,5.9,7.0,4.9,5.8,3.2,6.1,5.8,6.5,4.9,2.8,6.0,4.8,3.2,4.8,5.9,6.2,4.7,6.8,3.
2,5.3,4.2,6.5)
```

```
notas
```

```
hist(notas,plot=FALSE)
```

```
# hist construye un histograma
```

```
# pero al agregar "plot=FALSE", solo entrega
```

```
# los parametros del histograma, a saber:
```

```
# cortes, conteo por intervalo, densidad o proporcion, puntos medios, etc.
```

```
type=plot(notas,,"h")
```

```
# grafico de cajon:
```

```
boxplot(notas,
```

```
horizontal=TRUE, # dibujar el gráfico en forma horizontal
```

```
col="green", # color de relleno
```

```
main="Notas Ciencias Sociales", # título
```

```
xlab="Notas", # título eje horizontal
```

```
lwd=2, # ancho de lineas
```

```
ylim=c(1,7)) # límites eje horizontal
```

#####

EJEMPLO 17 Y 18 - NOTAS CIENCIAS SOCIALES (MEDIANA Y PERCENTILES)

```

notas<-
c(5.2,4.6,6.2,5.9,7.0,4.9,5.8,3.2,6.1,5.8,6.5,4.9,2.8,6.0,4.8,3.2,4.8,5.9,6.2,4.7,6.8,3.
2,5.3,4.2,6.5)

```

```

notas

```

```

# promedio o Media:

```

```

xbarra<-mean(notas)

```

```

xbarra

```

```

# mediana:

```

```

med<-median(notas)

```

```

med

```

```

# percentiles 25, 50, 75 (o cuartiles 1, 3 y mediana):

```

```

per<-c(0.25,0.50,0.75) # percentiles buscados

```

```

quantile(notas,per)

```

```

# el siguiente comando entrega varias medidas de resumen,

```

```

# minimo, máximo, mediana, media y cuartiles

```

```

summary(notas)

```

```

#####

```

EJEMPLO 20 - SUELDOS EMPLEADOS EMPRESA ACE

```

# ingreso del vector de datos:

```

```

sueldos<-c(320 , 326 , 326 , 345 , 347 , 370 , 379 , 394 , 402 , 409,
415 , 505 , 527 , 581.2 , 585 , 587 , 588 , 622 , 639 , 660,
671 , 678 , 689 , 694.5 , 707 , 746 , 746 , 776 , 790 , 741,
767 , 787 , 806 , 821.2 , 850 , 888 ,940 ,955 ,986 ,996,

```

```

1033 , 1128, 1165, 1171, 1181, 285, 1455 ,1682, 1887, 2675)
sueldos # visualizar los datos

# Calculos:
x<-sueldos
length(x) # numero de observaciones
q<-c(0.10,0.25,0.75,0.90) # percentiles de interes (como fracciones)
quantile(x,q) # percentiles
median(x) # mediana
mean(x) # media
summary(x) # resumen de descriptores
tit<-'Sueldos empres ACE' # definir titulo principal
titx<-'Sueldos (miles de pesos)' # definir titulo eje horizontal
tity<-'Frecuencia' # definir titulo eje vertical
boxplot(x,main=tit,xlab=titx,lwd=2,col='green',horizontal=T) # diagrama de cajon
hist(x,main=tit,xlab=titx,lwd=2,ylab=tity,col='green') # histograma
#####

```

EJEMPLO 21 - ESCOLARIDAD HABITANTES DE UN PUEBLO RURAL

```

escolaridad<-c(3, 5, 8, 8,8, 10, 10, 10, 10, 11, 11, 12, 12, 12, 12,
13,14,14,14,14,14)
escolaridad
# el programa siguiente es igual al del ejemplo 21, solo se redefine la
# variable x a escolaridad
x<-escolaridad
length(x)
q<-c(0.10,0.25,0.75,0.90)
quantile(x,q)

```

```

median(x)
mean(x)
summary(x)
tit<-'Escolaridad '
titx<-'Escolaridad (años)'
tity<-'Frecuencia'
boxplot(x,main=tit,xlab=titx,lwd=2,col='orange',horizontal=T)
hist(x,main=tit,xlab=titx,lwd=2,ylab=tity,col='orange')
#####

```

EJEMPLO 22 - TIEMPOS DE VIAJE LOCOMOCION COLECTIVA

```

tiempos<-c(44 ,48, 49, 51, 53, 53, 55, 55, 55, 56, 56, 58, 58, 59, 59, 59, 59, 60, 60,
60, 61, 61, 61, 61, 61, 61, 61, 61, 63, 63, 65, 66, 67, 67, 67, 69, 70, 72, 74, 75, 76)

tiempos
x<-tiempos
length(x)
q<-c(0.10,0.25,0.75,0.90)
quantile(x,q)
median(x)
mean(x)
summary(x)
tit<-'Tiempos de viaje'
titx<-'Tiempos (min)'
tity<-'Frecuencia'
boxplot(x,main=tit,xlab=titx,lwd=2,col='violet',horizontal=T)
hist(x,main=tit,xlab=titx,lwd=2,ylab=tity,col='violet')
# -----

```

EJEMPLO 23 - TIEMPOS DE VIAJE LOCOMOCION COLECTIVA CON VALORES EXTREMOS

```
tiempos2<-c(44 ,48, 49, 51, 53, 53, 55, 55, 55, 56, 56, 58, 58, 59, 59, 59, 59, 60,
60, 60, 61, 61, 61, 61, 61,
```

```
61, 61, 63, 63, 65, 66, 67, 67, 67, 69, 70, 72, 74, 75, 76,190,195)
```

```
tiempos2
```

```
x<-tiempos2
```

```
length(x)
```

```
q<-c(0.10,0.25,0.75,0.90)
```

```
quantile(x,q)
```

```
median(x)
```

```
mean(x)
```

```
summary(x)
```

```
tit<- 'Tiempos de viaje'
```

```
titx<- 'Tiempos (min)'
```

```
tity<- 'Frecuencia'
```

```
boxplot(x,main=tit,xlab=titx,lwd=2,col='violet',horizontal=T)
```

```
hist(x,main=tit,xlab=titx,lwd=2,ylab=tity,col='violet')
```

```
#####
```

EJEMPLOS 24 y 25 NOTAS CIENCIAS SOCIALES (VARIANZAS)

```
notas<-
```

```
c(5.2,4.9,6.5,3.2,6.8,4.6,5.8,4.9,4.8,3.2,6.2,3.2,2.4,5.9,5.3,5.9,6.1,6.0,6.2,4.2,7.0,5.
8,4.8,4.7,6.5)
```

```
notas
```

```
Prom<-mean(notas)
```

```
Prom # promedio (puntos)
```

```

s2<-var(notas) # varianza
s2 # varianza (puntos al cuadrado)
s<-sd(notas) # desviacion estandar
s # desviacion estandar (puntos)
CV<-s/Prom # coeficiente de variacion
CV # coeficiente de variacion (sin unidad)

# histograma:
brk <-c(9,1,2,3,4,5,6,7) # cortes rectangulos
hist(notas,col="green", # color de relleno
main="Notas Ciencias Sociales", # título
xlab="Notas", # título eje horizontal
lwd=2, # ancho de lineas
breaks=brk) # cortes rectangulos
#####

```

EJEMPLOS 24 y 25 NOTAS CIENCIAS SOCIALES (VARIANZAS)

```

notas<-
c(5.2,4.9,6.5,3.2,6.8,4.6,5.8,4.9,4.8,3.2,6.2,3.2,2.4,5.9,5.3,5.9,6.1,6.0,6.2,4.2,7.0,5.
8,4.8,4.7,6.5)

notas

Prom<-mean(notas)
Prom # promedio (puntos)
s2<-var(notas) # varianza
s2 # varianza (puntos al cuadrado)
s<-sd(notas) # desviacion estandar
s # desviacion estandar (puntos)

```

```
CV<-s/Prom # coeficiente de variacion
```

```
CV # coeficiente de variacion (sin unidad)
```

```
# histograma:
```

```
brk <-c(9,1,2,3,4,5,6,7) # cortes rectangulos
```

```
hist(notas,col="green", # color de relleno
```

```
main="Notas Ciencias Sociales", # título
```

```
xlab="Notas", # título eje horizontal
```

```
lwd=2, # ancho de lineas
```

```
breaks=brk) # cortes rectangulos
```

```
#####
```

EJEMPLO 28 - EXPERIENCIA Y SUELDOS DE FUNCIONARIOS

```
# ingreso de datos:
```

```
sueldo<-read.table(header=TRUE,text='
```

```
Funcionario Experiencia Sueldo Estamento
```

```
1      1      400  2
```

```
2      7     1951  1
```

```
3      3      952  1
```

```
4     12     1650  1
```

```
5      6     1230  1
```

```
6      7     1090  2
```

```
7     11     2405  1
```

```
8     19     2580  1
```

```
9     17     2850  1
```

```
10    10     1805  2
```

```
11     4      560  2
```

```
12     6      980  2
```

```

13      12      2848  1
14      16      2609  1
15      10      1615  2

```

```
) # fin del ingreso de datos. header=TRUE indica que tienen encabezado
```

```
attach(sueldo) # permite utilizar las variables en forma independiente de la tabla
# sin esto se debe mencionar el marcode datos. Por ejemplo: sueldo$Estamento
str(sueldo)
```

```
color<-Estamento+1 # define colores verde (1) y rojo (2)
```

```
rangox<-c(0,20) # define límites eje horizontal
```

```
rangoy<-c(300,3000) #define límites eje vertical
```

```
plot(Experiencia,Sueldo) # este comando construye un diagrama de dispersion muy
basico
```

```
# El siguiente es el mismo diagrama, pero controlando varias de sus características
(parametros):
```

```
plot(Experiencia,Sueldo, # diagrama de dispersión. Los siguientes son sus
parametros:
```

```
col=color, # color puntos
```

```
xlim=rangox, # rango horizontal
```

```
ylim=rangoy, # rango vertical
```

```
xlab='Experiencia (años)', # título horizontal
```

```
ylab='Sueldo (miles de pesos)', # título vertical
```

```
main='Sueldo versus Experiencia', # título principal
```

```
pch=16, # tipo de símbolo: círculo
```

```
cex=2) # tamaño símbolo
```

```
# agregar rotulos:
```

```
text(Experiencia+1, # rótulos en cada punto: posición horizontal
```

```
Sueldo-20, # posición vertical
```

```
labels=Funcionario) # rótulos
```

```
# agregar una explicación de los colores que representan los Estamentos:
```

```
legend("bottomright", # leyenda en posición abajo a la derecha
```

```
title="Estamento", # título leyenda
```

```
title.col="black", # color titulo leyenda
```

```
legend=c("Administrativo","Profesional"), # nombres leyenda
```

```
text.col=color) # colores rotulos leyenda
```

```
#####
```

EJEMPLO 29 - GENERACION DE ENERGIA ELECTRICA

```
# leer tabla de datos:
```

```
energia<-read.table(header=TRUE,text='
```

```
mes ter hid tri sem
```

```
Ene 1475 2480 1 1
```

```
Feb 1549 2158 1 1
```

```
Mar 1741 2307 1 1
```

```
Abr 1863 1868 2 1
```

```
May 2172 1790 2 1
```

```
Jun 2486 1525 2 1
```

```
Jul 2560 1700 3 2
```

```
Ago 2654 1427 3 2
```

```
Sep 2260 1594 3 2
```

```
Oct 1934 2004 4 2
```

```
Nov 1775 2036 4 2
```

```
Dic 2196 1874 4 2
```

```
') # fin ingreso de datos
```

```
# cada variable es un vector:
```

```

energia$ter
energia$hid
energia$mes
# para poder usarlas independientemente de la tabla de datos:
attach(energia)
# operaciones con vectors:
tot<-ter+hid # energia total
tot
mean(tot) # promedio de energia a traves de todos los meses

# diagrama de dispersion de hid (vertical) versus ter (horizontal)

color<-tri+1 # definir colores por cada trimestre
rango<-c(1400,2800) # definir rango de los ejes
plot(ter,hid, # grafico de ter versus hid con sus características (parametros):
col=color, # colores puntos
xlim=rango, # rango eje horizontal
ylim=rango, # rango eje vertical
main='Generación de energía en 2007', # titulo del grafico
xlab='Térmica (MMKw)', # rotulo eje horizontal
ylab='Hidráulica (MMKw)', # rotulo eje vertical
pch=16, # tipo de simbolo (en este caso un circulo)
cex=2) # tamaño de los circulos
text(ter+80,hid+10,labels=mes) # rotulos puntos

# graficos de lineas de los dos tipos de generacion y el total;
ms<-1:12 # definir Mes
plot(ms,ter+hid, # grafico de Generacion versus Mes

```

```

type="o", # tipo de grafico; use los puntos, representados por circulos
xlim=c(0,12), # rango eje horizontal
ylim=c(0,4200), # rango eje vertical
lwd=2, # define ancho de linea
xaxt="n", # no escribir los valores en el eje horizontal
col="violet", # define color de las lines y puntos
main="Generación eléctrica en 2007", # titulo del grafico
xlab="Mes", # rotulo del eje horizontal
ylab="Generación (MMKw)") # rotulo eje vertical
axis(1, at = 1:12,labels = ms) # define rotulos puntos del eje horizontal
lines(ms,ter,type="o",col="red",lwd=2) # agrega lines correspondiente a Termica,
color rojo
lines(ms,hid,type="o",col="blue",lwd=2) # agrega lines correspondiente a Hidraulica,
color azul
legend("bottomleft", # explicación de los colores de los graficos
title="Generación",title.col="black",legend=c("Térmica","Hidráulica","Total"),text.col=c
("red","blue","violet"))
#####

```

EJEMPLO 30 - GASTOS EMPRESAS DE TRANSPORTE

```
# leer base de datos (data frame):
```

```
gastos<-read.table(header=TRUE,text='
```

| Id | RT | MU | Tel | Pr | Mant | GPS | GO | ICP | Prm |
|----|------|------|------|------|------|------|------|------|------|
| 1 | 166 | 2345 | 769 | 1115 | 0 | 0 | 2300 | 837 | 942 |
| 2 | 2700 | 900 | 0 | 2850 | 3489 | 500 | 654 | 1850 | 1618 |
| 3 | 82 | 1775 | 2389 | 534 | 737 | 2689 | 412 | 71 | 1086 |
| 4 | 122 | 42 | 210 | 450 | 1225 | 200 | 0 | 100 | 294 |
| 5 | 1305 | 1380 | 1256 | 1654 | 2658 | 1239 | 0 | 2160 | 1457 |
| 6 | 0 | 7 | 405 | 0 | 0 | 1296 | 397 | 47 | 269 |

| | | | | | | | | | |
|----|------|------|------|------|------|------|------|------|------|
| 7 | 246 | 1763 | 294 | 2849 | 1346 | 3913 | 2005 | 1953 | 1796 |
| 8 | 201 | 1140 | 774 | 3509 | 0 | 0 | 702 | 322 | 831 |
| 9 | 41 | 630 | 397 | 195 | 0 | 628 | 3348 | 174 | 677 |
| 10 | 300 | 0 | 300 | 300 | 0 | 475 | 0 | 300 | 209 |
| 11 | 63 | 323 | 882 | 1040 | 76 | 0 | 458 | 138 | 373 |
| 12 | 1821 | 1123 | 894 | 1837 | 3200 | 2810 | 2060 | 2892 | 2080 |
| 13 | 100 | 200 | 180 | 200 | 0 | 34 | 420 | 147 | 160 |
| 14 | 0 | 963 | 1991 | 758 | 1215 | 1122 | 126 | 189 | 796 |
| 15 | 200 | 0 | 456 | 300 | 0 | 1266 | 445 | 0 | 333 |
| 16 | 94 | 237 | 900 | 0 | 2418 | 345 | 0 | 130 | 516 |
| 17 | 100 | 50 | 200 | 500 | 2000 | 300 | 0 | 100 | 406 |
| 18 | 298 | 265 | 432 | 778 | 711 | 720 | 345 | 456 | 501 |
| 19 | 24 | 1254 | 0 | 720 | 0 | 1728 | 0 | 267 | 499 |
| 20 | 93 | 186 | 756 | 347 | 782 | 0 | 2348 | 893 | 676 |
| 21 | 40 | 557 | 1500 | 1595 | 0 | 0 | 1234 | 205 | 641 |
| 22 | 100 | 50 | 200 | 500 | 2000 | 300 | 126 | 100 | 422 |
| 23 | 450 | 1234 | 300 | 200 | 0 | 541 | 800 | 210 | 467 |
| 24 | 45 | 236 | 0 | 175 | 0 | 0 | 456 | 17 | 116 |
| 25 | 520 | 30 | 0 | 200 | 0 | 234 | 2225 | 1089 | 537 |
| 26 | 3080 | 720 | 372 | 1000 | 0 | 1000 | 0 | 900 | 884 |
| 27 | 138 | 2013 | 580 | 2732 | 358 | 3354 | 2539 | 713 | 1553 |
| 28 | 1843 | 515 | 1089 | 886 | 1225 | 1782 | 2710 | 1892 | 1493 |
| 29 | 140 | 3194 | 1182 | 500 | 267 | 677 | 0 | 450 | 801 |
| 30 | 756 | 1129 | 1524 | 3017 | 0 | 0 | 2467 | 524 | 1177 |
| 31 | 0 | 2166 | 0 | 0 | 342 | 127 | 13 | 0 | 331 |
| 32 | 1 | 1377 | 141 | 619 | 75 | 1660 | 636 | 1083 | 699 |
| 33 | 80 | 133 | 982 | 504 | 3587 | 850 | 1237 | 0 | 922 |
| 34 | 720 | 240 | 0 | 347 | 834 | 560 | 0 | 1595 | 537 |
| 35 | 36 | 101 | 909 | 1905 | 3219 | 400 | 1912 | 646 | 1147 |
| 36 | 36 | 327 | 900 | 0 | 1860 | 1112 | 0 | 50 | 536 |

```

37  139  950  85   2594  3094  3344  1097  913  1527
38   23   11  234  486  135   8     0    46  118
39   75  500  675  875  2345  783   0   250  688
40  116  234   0   400  3218  794   0   152  614
41  290  2040  3500  1440  3467  1127  713  490  1633
42   52   0   630  1180  0     651  3481  402  800
43  841  1188  3284  700   0     0   3079  780  1234
44  350  300  481  2000  0     0     0   459  449
45   15   0   720  120  1800  76   341  96   396
46  166  2345  769  1115  0     0     0  2300  837

```

```
')
```

```
n<-ncol(gastos) # numero de columnas (observaciones)
```

```
color<-c(rep("yellow",8),"green") # define vector de colores 8 amarillos un verde
```

```
# diagrama de cajon :
```

```
boxplot(gastos[,2:10], # Diagramas de cajon de cada columna de la base de datos
```

```
# si se quisiera pro filas, se escribe gastos[2:46,]. La coma separa filas (hor) de
columnas (vert)
```

```
col=color, # colores segun vector de colores
```

```
horizontal=TRUE, # cajas en forma horizontal
```

```
lwd=2,main="Gasto anual de empresas de transporte", # titulo del grafico
```

```
xlab="Gasto (Millones de pesos)", # rotulo eje horizontal
```

```
ylab="Rubro") # rotulo eje vertical
```

```
#####
```

Explicación acerca de las franjas de colores

Usadas en el texto

EJEMPLO

Ejemplos resueltos que ilustran los conceptos presentados.

Los ejemplos aparecen a continuación de los conceptos que se pretendió explicar con anterioridad.

MOTIVACIÓN

Similares a los Ejemplos, pero puestos antes de los conceptos, con el objeto de despertar el interés de los estudiantes hacia lo que se presentará a continuación.

ACTIVIDAD PRÁCTICA

Actividades propuestas que implican la aplicación práctica de los conceptos, a través de alguna acción física.

ACTIVIDAD COMPUTACIONAL

Actividades propuestas que implican la aplicación de los conceptos, a través de acciones realizadas utilizando un programa computacional, como Excel o R.

EJERCICIOS

Ejemplos de aplicación de los conceptos presentados al final de cada sección, para ser resueltos por los estudiantes.

INDICE ALFABÉTICO

Adquisición de datos, 9
Aleatorio, al azar, 21, 24
Análisis de datos, 30
Asimetría, 58, 64, 70, 73,109
Asimetría negativa, a la izquierda, 77
Asimetría positiva, a la derecha, 73
Asociación, medida de asociación, 95, 96
Asociación negativa, 96
Asociación positiva, 95, 99

Bigotes, 68, 69

Característica, 11
Categoría, 11,38
Centro, 28, 44
Clasificar, 43
Coeficiente de variación, 84, 86, 89
Conocimiento, 9, 10
Cuartil, 62, 63, 88

Datos, 9, 30
Datos a granel, 37, 38, 41
Datos categóricos, no numéricos, 37
Datos interiores, 68
Decil, 63
Decisiones, 9, 10

Desviación estándar, 84, 87, 90

Diagrama de cajón, cajagrama, cajón con bigotes, 67, 70, 76

Dispersión, 89

Enumerar, 15, 16

Escala categórica, 15, 24

Escala categórica nominal, 15, 16

Escala categórica ordinal, 15, 17

Escala de medida, 12, 13

Escala dicotómica o binaria, 16, 24

Escalas finitas e infinitas, 15

Escala numérica, 15

Estadística, 7

Experimento, 32

Frecuencias, 47

Gráfico, 8

Gráfico estadístico, 48

Gráfico de barras, 37, 38, 40, 47

Histograma, 37, 42

Indicador, 8

Infograma, 48, 49, 50

Información, 7, 9

Instrumento de medida, 12, 14

Intervalo, 42

Límites de intervalos, 44

Medida, indicador, 8

Medida de asociación, 94, 96

Medida de centro, de tendencia central, 28, 52, 54

Medida de dispersión, 84, 90

Medida de posición, 59

Medida robusta, 65,67, 74

Mediana, 52, 55, 57, 65

Medir, 11

Modelos estadísticos, 8

Muestra, 20, 21

Número, 11

Números reales, 46

Orden natural, 15

Percentil, 59, 61, 65

P_i , 17

Población, 20, 21

Población objetivo, 24, 52, 57

Quintil, 63

Rango, 88

Rango intercuartil, 62, 67, 69, 88, 90

Reposición, 27, 28

Resumir información, 7, 40, 52

Robustez, medida robusta, 65, 67

Selección al azar, 27

Simetría, 64, 71, 88

Tabla, 8

Tabla de doble entrada, 39

Tabla de frecuencias, 37, 38, 42, 44, 45

Valores extremos, 57, 68, 70, 87, 80

Variable continua, 15

Variable discreta, 15

Variable en estudio, 15, 22, 24

Variación, 32

Varianza, 84, 87

EL AUTOR

Jorge Mauricio Galbiati Riesco, Ph.D.

Doctor en Estadística, Universidad de Iowa, U.S.A

Master en Estadística Matemática, Centro Interamericano de Enseñanza de Estadística (CIENES), Universidad de Chile.

Profesor de Matemáticas y Física y Licenciado en Filosofía y Educación, Universidad Católica de Valparaíso.



Académico de la Pontificia Universidad Católica de Valparaíso desde 1971. Ejerce en el Instituto de Estadística desde su fundación, en 1975. Fue su Director entre 2001 y 2006.

Ha ejercido la docencia desde 1971, elaborando gran cantidad de material didáctico.

Ha participado en varios proyectos de investigación, con un número de publicaciones en revistas científicas internacionales, fundamentalmente en el tema de Procesamiento Estadístico de Imágenes Digitales.

Ha tomado parte de numerosos proyectos de asesoría a instituciones y empresas.

Entre 2008 hasta 2011 fue miembro del Consejo Superior de la Pontificia Universidad Católica de Valparaíso.

Fue miembro del Consejo Nacional de Estadísticas, entre 2010 y 2011, en representación del Consejo de Rectores de las Universidades Chilenas.

www.jorgegalbiati.cl
