Visualizando Distribuciones y Medidas Robustas

Unidad 4: Estadística Descriptiva Univariada

Gabriel Sotomayor

2025-10-20

Objetivos de la Sesión de Hoy

- **Introducir** el marco para describir una variable cuantitativa: **Forma, Centro y Dispersión**.
- **Aprender** a visualizar la **forma** de una distribución usando **Histogramas**.
- **Calcular e interpretar** las medidas de **centro** y **dispersión robustas**: **Mediana**, **Cuartiles** y **Rango Intercuartil (IQR)**.
- **Construir e interpretar** el **Resumen de Cinco Números** y su visualización: el **Boxplot**.

1. Descripción de Variables Cuantitativas

De las Categorías a los Números

En la clase anterior, aprendimos a describir variables categóricas contando casos y mostrando porcentajes (`table`, `count`, `geom_bar`).

Hoy, pasamos a las **variables cuantitativas** (de intervalo o razón), como la edad, los ingresos o los años de escolaridad.

Con estas variables, un simple conteo no es suficiente. Necesitamos herramientas para describir su **distribución**: cómo se reparten los valores a lo largo de un rango numérico.

Análisis Exploratorio de Datos

Al enfrentarnos a una variable cuantitativa, nuestro objetivo es describir tres características fundamentales de su distribución:

1. **Forma:** ¿Cuál es el aspecto general de la distribución? ¿Es simétrica o asimétrica? ¿Tiene uno o varios picos (modas)?
2. **Centro:** ¿Alrededor de qué valor se agrupan los datos? ¿Cuál es el “caso típico”?
3. **Dispersión (o Variabilidad):** ¿Qué tan extendidos o concentrados están los datos?

Además, siempre debemos estar atentos a la presencia de **valores atípicos (outliers)**, que son observaciones que se desvían marcadamente del patrón general.

2. Visualizando la Forma: Histogramas

El Histograma: Un Retrato de la Distribución

El **histograma** es la principal herramienta gráfica para visualizar la forma de la distribución de una variable cuantitativa.

- **¿Cómo se construye?**
  1. El rango de la variable se divide en intervalos de igual ancho, llamados “bins” o “clases”.
  2. Se cuenta cuántas observaciones caen dentro de cada intervalo.
  3. Se dibuja una barra para cada intervalo, donde la altura de la barra es proporcional a la frecuencia.

A diferencia de un gráfico de barras, en un histograma el eje X es continuo y las barras van juntas.

Ingreso del Trabajo Principal en Chile

Para ilustrar estos conceptos, usaremos la **Encuesta Suplementaria de Ingresos (ESI) 2024** del INE. Nos centraremos en la variable `ing_t_p` (ingreso del trabajo principal) para los ocupados de referencia.

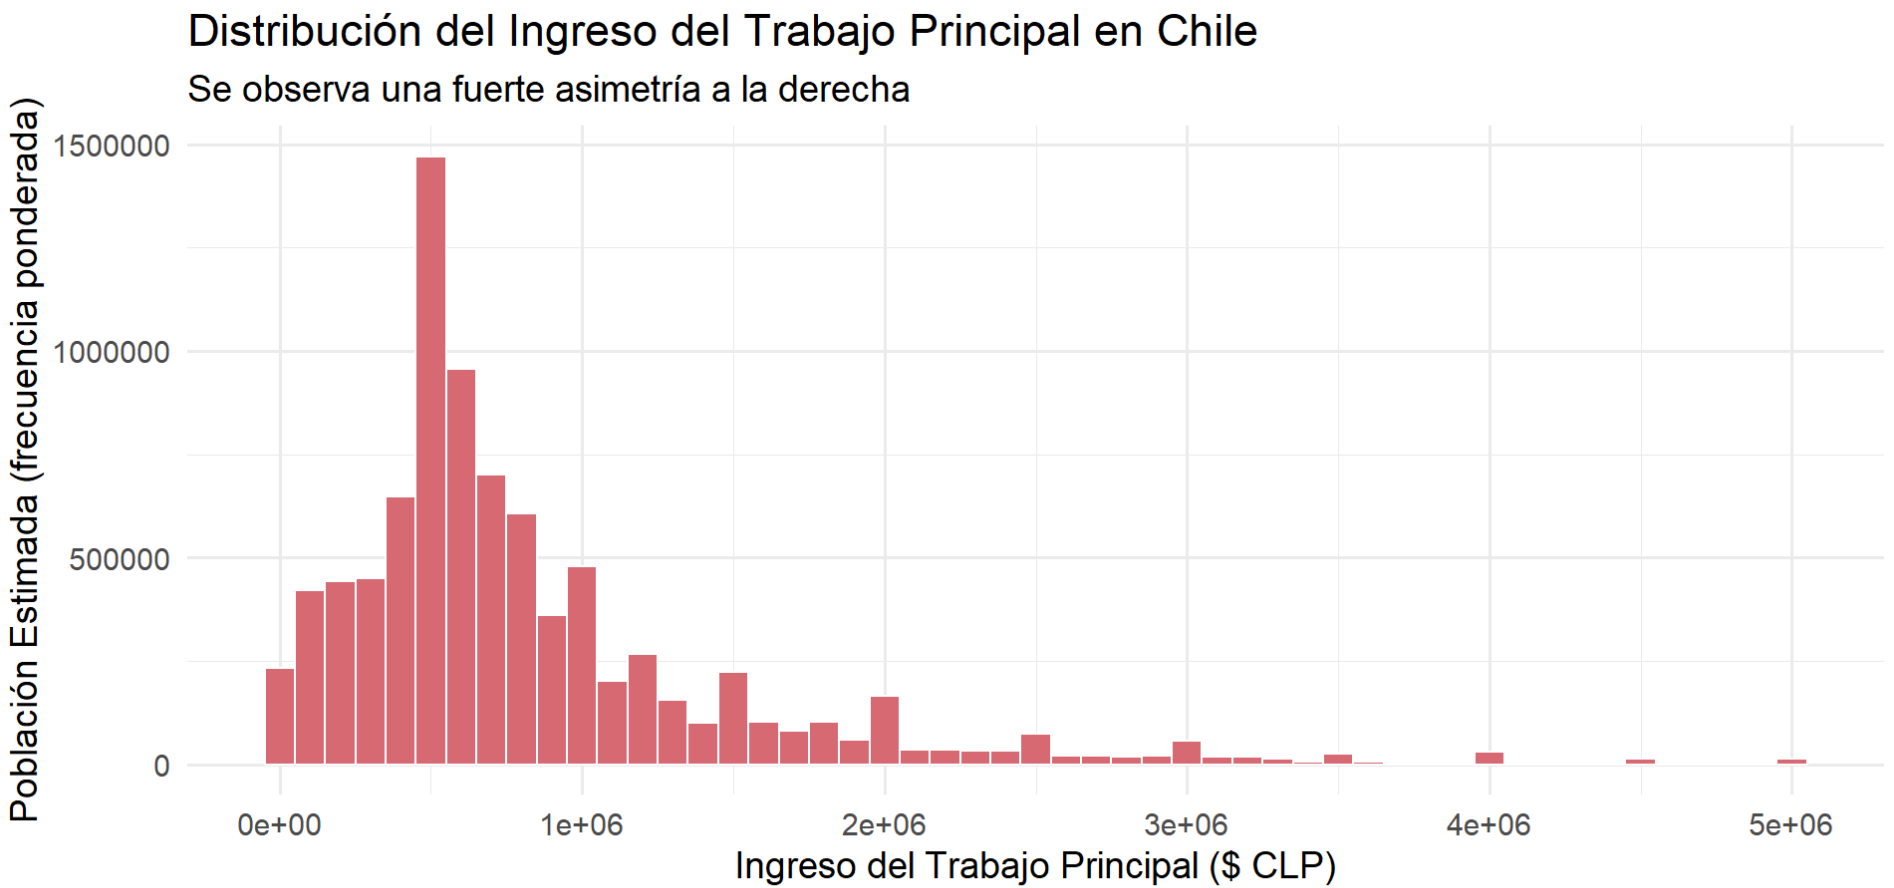

Fuente: Elaboración propia a partir de ESI 2024.

La Fuente de Datos: Encuesta Suplementaria de Ingresos (ESI)

- **¿Qué es?** La ESI es un módulo que se aplica anualmente (en el trimestre octubre-diciembre) a una submuestra de los hogares que participan en la **Encuesta Nacional de Empleo (ENE)**. Es la principal fuente de datos sobre ingresos en Chile.
- **Objetivo Principal:** Caracterizar en detalle los ingresos de las personas y los hogares, yendo mucho más allá de lo que la ENE puede capturar por sí sola. Mide:
  - Ingresos del trabajo principal y secundario.
  - Ingresos de fuentes no laborales (jubilaciones, arriendos, etc.).
  - Ingresos por trabajador/a por cuenta propia.
- **Relevancia Sociológica:** Los datos de la ESI son cruciales para analizar la **desigualdad económica**, la **brecha salarial de género** y la estructura del mercado laboral en Chile. Cuando leemos en las noticias sobre la “mediana del ingreso” en el país, esa cifra proviene de esta encuesta.

Interpretando la Forma: Asimetría (Sesgo)

La asimetría describe si la distribución está “cargada” o tiene una cola más larga hacia un lado.

Interpretando la Forma: Modalidad

La modalidad se refiere al número de picos o modas que tiene una distribución.

- **Unimodal:** La distribución tiene un solo pico principal. Es la forma más común, indicando que hay un valor o rango de valores claramente más frecuente que los demás.
- **Bimodal:** La distribución tiene dos picos distintos. A menudo es una señal importante de que nuestros datos provienen de **dos subgrupos diferentes** que no hemos separado.
    - *Ejemplo:* La distribución de estaturas en una muestra que mezcla hombres y mujeres probablemente será bimodal.
- **Multimodal:** Tiene varios picos.

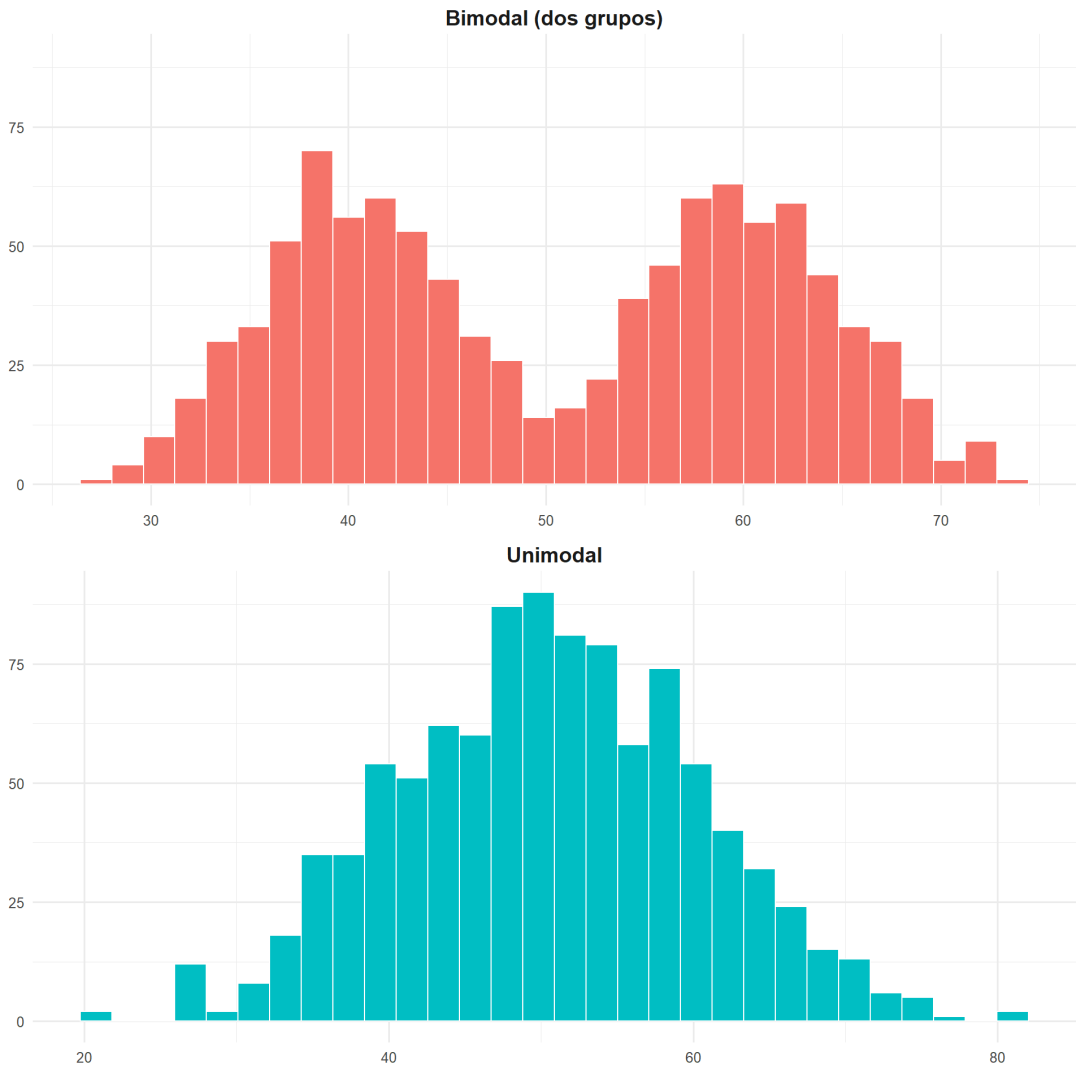

3. Medidas de Centro y Dispersión Robustas

¿Qué es una Medida Robusta?

Una medida estadística es **robusta** si **no se ve afectada significativamente** por la presencia de valores extremos (outliers) o por la asimetría de la distribución.

Ejemplo:

- Datos: `1, 2, 3, 4, 100`
- La presencia del `100` es un outlier.
- Una medida robusta del centro debería estar cerca de `3`, ignorando la influencia desproporcionada del `100`.

Hoy nos centraremos en las medidas robustas, que son ideales para describir distribuciones como la del ingreso.

La Mediana (M o Q2): El Centro Geométrico

La **mediana** es el valor que se encuentra en el punto medio exacto de los datos, una vez que han sido ordenados de menor a mayor.

- **Definición:** Es el **percentil 50**. Deja al 50% de las observaciones por debajo y al 50% por encima.
- **Propiedad Clave:** Es una medida de centro **robusta**. Su valor depende de la posición de los datos, no de su magnitud.

Ejemplo:

- Datos ordenados: `1, 2, **3**, 4, 100` -> La mediana es **3**.
- Datos ordenados: `1, 2, **3**, 4, 10000` -> La mediana sigue siendo **3**.

El outlier no afecta a la mediana. Por eso es la medida preferida para describir el “ingreso típico” en una población.

Cuartiles y Rango Intercuartil (IQR)

Así como la mediana divide los datos en dos mitades, los **cuartiles** los dividen en cuatro partes iguales.

- **Primer Cuartil (Q1):** Es el percentil 25. Deja al 25% de los datos por debajo.
- **Tercer Cuartil (Q3):** Es el percentil 75. Deja al 75% de los datos por debajo.

A partir de los cuartiles, construimos la principal medida de dispersión robusta:

- **Rango Intercuartil (IQR):** Es la distancia entre el tercer y el primer cuartil (`IQR = Q3 - Q1`).
- **Interpretación:** El IQR representa el **rango en el que se encuentra el 50% central de los datos**. Al igual que la mediana, es una medida de dispersión **robusta** porque ignora los valores en las colas de la distribución.

Percentiles: Más Allá de los Cuartiles

Los cuartiles son solo un tipo de **percentil** (o **cuantil**), un concepto más general y flexible para describir la posición de un valor dentro de una distribución ordenada.

- **Definición General:** El **percentil *p*** es el valor por debajo del cual se encuentra el *p*% de las observaciones.
  - La mediana es el percentil 50.
  - El primer cuartil (Q1) es el percentil 25.
  - El tercer cuartil (Q3) es el percentil 75.

Ejemplo: Los Quintiles de Ingreso

En sociología y políticas públicas, es muy común dividir a la población en **cinco grupos** de igual tamaño (20% cada uno). A estos grupos se les llama **quintiles**. Para definirlos, calculamos los percentiles 20, 40, 60 y 80.

Ejemplo con la ESI 2024:

Percentil	Ingreso Límite
P20	$400.000
P40	$548.629
P60	$750.000
P80	$1.200.000

- Una persona en el **primer quintil** gana hasta $400.000.
- Una persona en el **quinto quintil** (el 20% más rico) gana más de $1.200.000.

Podemos usar cualquier percentil para analizar la desigualdad. Por ejemplo, el **percentil 99** nos diría cuál es el ingreso del 1% más rico de la población.

El Resumen de Cinco Números y el Boxplot

El **resumen de cinco números** es el conjunto estándar de estadísticas robustas para describir una variable cuantitativa.

Componentes:

1. **Mínimo**
2. **Primer Cuartil (Q1)**
3. **Mediana (M o Q2)**
4. **Tercer Cuartil (Q3)**
5. **Máximo**

Este resumen se visualiza directamente a través de un **diagrama de caja y bigotes** o **boxplot**.

El Resumen de Cinco Números en la Práctica

Apliquemos estos conceptos a nuestra variable `ing_t_p` (ingreso del trabajo principal) de la ESI 2024. Este es el resumen numérico estándar para describir una distribución, especialmente si es asimétrica como la del ingreso.

Componentes: Mínimo, Primer Cuartil (Q1), Mediana, Tercer Cuartil (Q3) y Máximo.

Resumen de Cinco Números para el Ingreso del Trabajo Principal ($ CLP)

Medida	Ingreso Mensual
Mínimo	2.993
Q1 (Percentil 25)	461.456
Mediana (Percentil 50)	626.045
Q3 (Percentil 75)	1.009.749
Máximo	60.756.649

La Anatomía de un Boxplot

Un **diagrama de caja y bigotes** o **boxplot** es la visualización directa del resumen de cinco números y una de las herramientas más informativas de la estadística descriptiva.

- **La Caja:** Representa el **Rango Intercuartil (IQR)**. Su longitud es una medida visual de la dispersión del 50% central de los datos.
- **La Línea Central:** Marca la **mediana** (Q2 o percentil 50).
- **Los Bigotes:** Se extienden hasta los valores mínimo y máximo “típicos” (generalmente 1.5 veces el IQR desde la caja).
- **Los Puntos:** Representan **valores atípicos (outliers)**, que son observaciones que caen más allá de los bigotes, permitiendo identificarlos fácilmente.

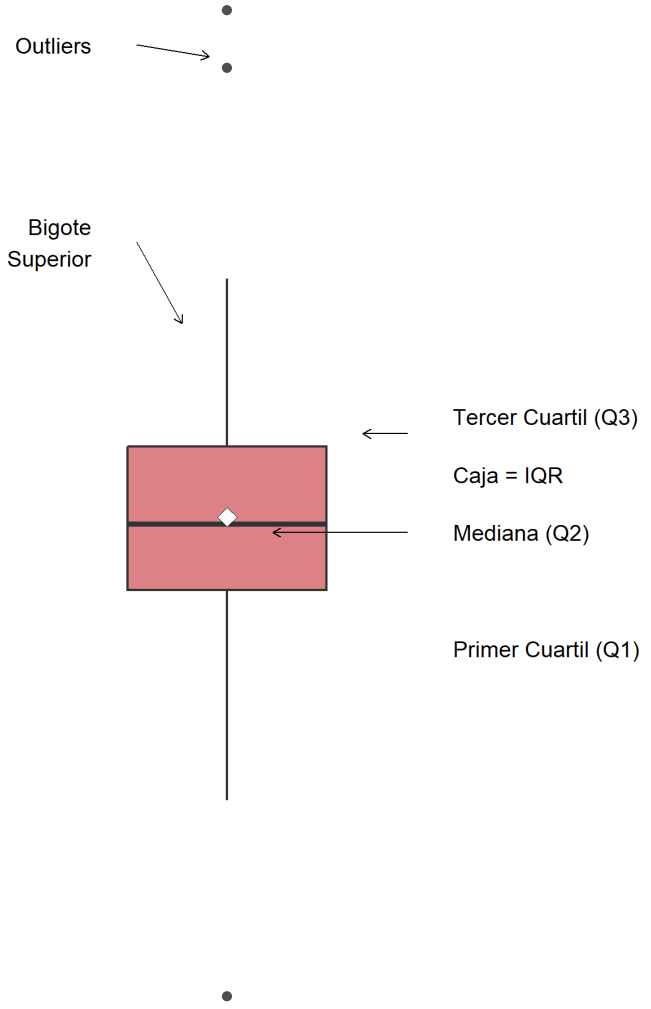

El Boxplot de Ingreso del Trabajo Principal

Apliquemos el boxplot a la variable de ingreso de la ESI 2024. Este gráfico nos permite ver de un solo vistazo la forma, el centro, la dispersión y la enorme cantidad de outliers.

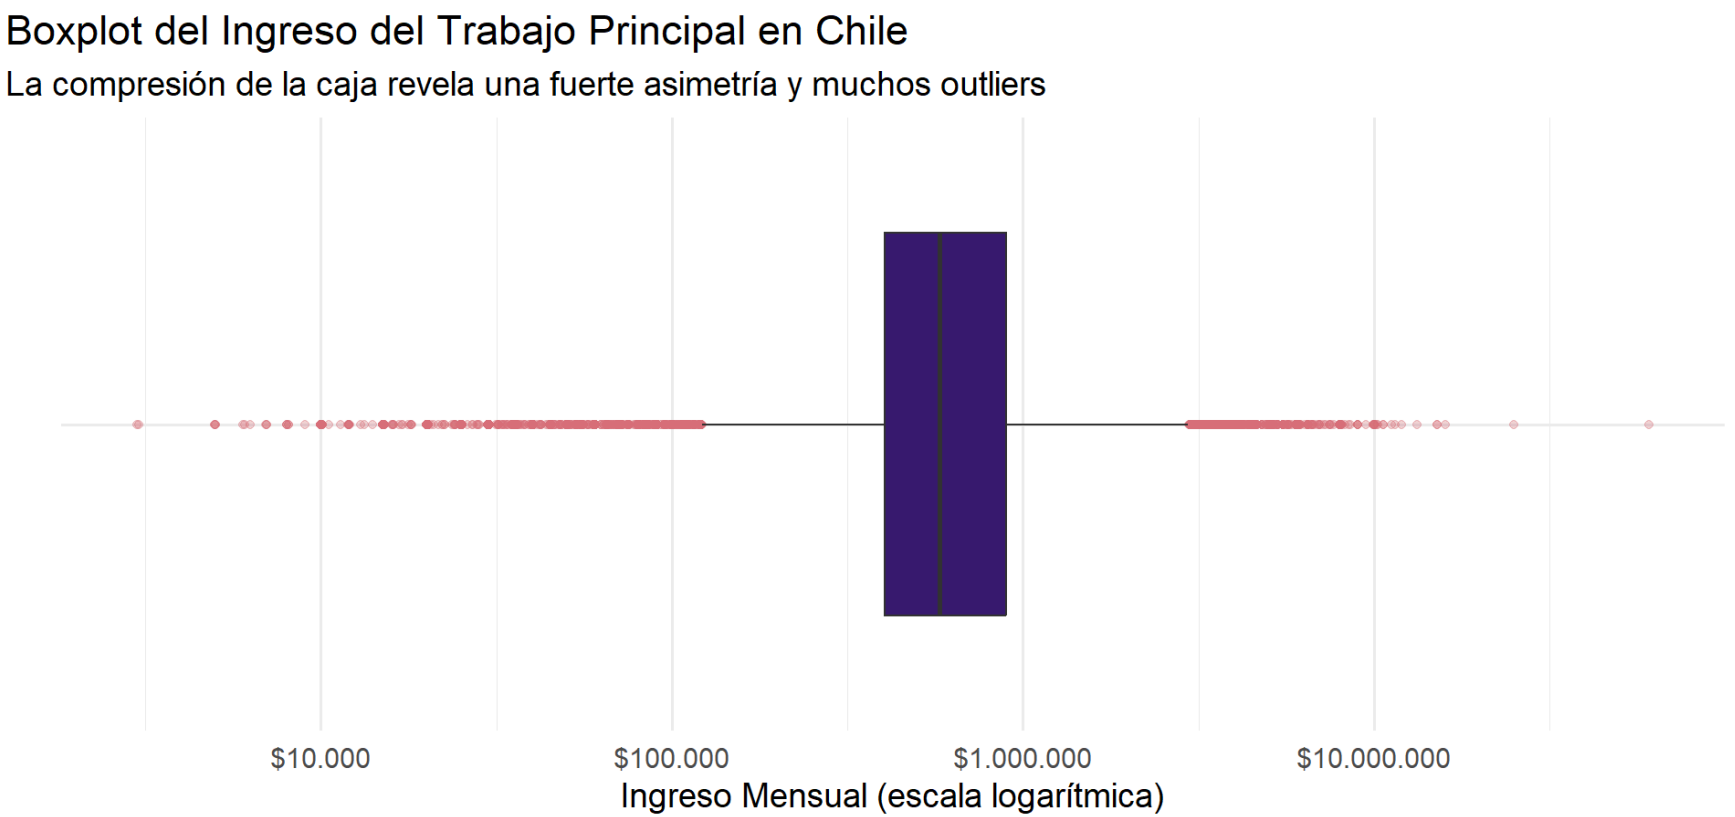

Fuente: ESI 2024

La Escala Logarítmica

En el gráfico anterior, para poder visualizar la distribución del ingreso, aplicamos una transformación al eje: una **escala logarítmica**. Esta es una herramienta fundamental cuando trabajamos con variables que, como el ingreso, tienen una **fuerte asimetría positiva**.

- **El Problema de la Asimetría:** Cuando unos pocos valores muy altos (como los ingresos de las personas más ricas) son miles de veces más grandes que la mayoría, “aplastan” el resto del gráfico. La caja y los bigotes del boxplot, o un histograma, se comprimen tanto en la parte inferior que se vuelven casi invisibles, y perdemos toda la información sobre el 50% o 75% inferior de la población.

La Escala Logarítmica

¿Qué hace una Escala Logarítmica?

Una escala estándar (lineal) muestra los valores en sus unidades absolutas. La distancia entre 100.000 y 200.000 es la misma que entre 2.000.000 y 2.100.000.

Una escala logarítmica, en cambio, representa **órdenes de magnitud**. La distancia en el eje es la misma para cada **multiplicación** (usualmente x10). La distancia entre $100.000 y $1.000.000 (x10) es la misma que entre $1.000.000 y $10.000.000 (x10).

El Efecto Práctico:

Cierre y Próximos Pasos

Resumen de la sesión de hoy:

- Introdujimos el marco **Forma-Centro-Dispersión** para describir variables cuantitativas.
- Aprendimos a usar **histogramas** para visualizar la forma (asimetría, modalidad).
- Definimos y calculamos las **medidas robustas** de centro (**mediana**) y dispersión (**IQR**).
- Vimos cómo el **resumen de cinco números** se traduce en un **boxplot**, una poderosa herramienta visual.

En el práctico de hoy:

- Aplicarán estas técnicas en R para describir variables de la Encuesta CASEN, usando `geom_histogram`, `geom_boxplot`, `summary()` y `quantile()`.

Adelanto de la próxima clase:

- Exploraremos el otro par de medidas descriptivas: la **media** y la **desviación estándar**. Veremos por qué no son robustas y cuándo es apropiado usarlas.