

# Capítulo 1: Instalar R

Vamos a empezar con los pasos para la instalación de R en los sistemas operativos Windows, MacOS y Linux.

## Descargar R

1. Ve al sitio web oficial de R en <https://www.r-project.org/>
2. haz clic en donde diga **Download R**.
3. En la lista mirrors, busca <https://cran.itam.mx/> y hacer click.

*continuamos en la sección correspondiente a tu sistema operativo:*

## Instalar R en Windows

1. Hacer click donde diga *Download for Windows* y guarda el archivo ejecutable.
2. Corre el archivo .exe y seguir las instrucciones de instalación.

## Instalar R en macOS

1. Hacer click donde diga *Download for macOS*.
2. Hacer click en el link del archivo de la versión mas reciente de R.
3. Correr el archivo .pkg y seguir las instrucciones de instalación.

## Instalar R en Linux

1. Hacer click donde diga *Download for Linux*.
2. Selecciona tu distribución de Linux y sigue las instrucciones para instalar desde la terminal.

## Capítulo 2: ¿Para qué usar R?

### Orígenes y usos

R es un software estadístico basado en los lenguajes *S* y *Scheme*. Por un lado, *S* es un lenguaje de programación desarrollado por Rick Bercker, John Chambers y colegas en Bell Labs en los años ochentas. Tiene como principal objetivo alentar y permitir el buen análisis estadístico.

En cuanto a R, todo comenzó en agosto de 1993 como un experimento realizado por Ross Ihaka y Robert Gentleman, ellos reconocieron la necesidad de un mejor ambiente de cálculo del que tenían. Ninguno de los productos comerciales les convencían por lo que decidieron crear una herramienta que les funcionara. Esto los llevo a tomar ideas de *S*, donde les resultó natural usar una sintaxis parecida. Por lo que, en el uso diario, *S* y R son muy similares, pero R no es *S*.



Figura 1: Robert Gentleman (izquierda) y Ross Ihaka (derecha), creadores de R

Fuente: Manual de R

Las diferencias entre ellos son resultado de la herencia de *Scheme*, fundamentalmente el manejo de la memoria y el acceso a las variables dependiendo de dónde fueron definidas. También se distingue el manejo del color, áreas de graficación, rotulación matemática, entre otros.

Algunas fechas importantes en el desarrollo de R: en febrero de 2000 sale finalmente la versión 1.0 de R; en 2001 se publica el primer número de *R-News*, revista electrónica dedicada a la discusión y anuncios de nuevos procedimientos y paquetes de R; la revista es reemplazada por *R-Journal* en 2009.

Finalmente, para garantizar que R sea siempre un software libre de código abierto, se creó *R-foundation* que entre sus objetivos están:

1. Avanzar el proyecto de R para cálculo estadístico que provee de software libre y código abierto para el análisis de datos y gráficas.
2. Guardar y administrar los derechos de copia de R y su documentación. <sup>1</sup>

<sup>1</sup>Barrios, E.(2010). R: Un lenguaje para análisis de datos y graficación. Recuperado de: <https://gente.itam.mx/ebarrios/docs/porqueR.pdf>

## ¿Qué se puede hacer con R?

R es una herramienta versátil que, en un principio, ofrece un conjunto robusto de funciones estadísticas para el análisis de datos, evaluación de algoritmos, modelos lineales y no lineales, pruebas estadísticas, entre otros. Además, R puede extenderse hasta campos avanzados como el machine learning, una rama fundamental de la inteligencia artificial. Su alcance abarca diversas áreas, como las siguientes:

- **Análisis y Visualización de Datos:** Procesamiento, análisis estadístico y generación de gráficos avanzados.
- **Tareas Académicas:** Resolución de ejercicios estadísticos, desarrollo de trabajos y tareas académicas.
- **Programación y Desarrollo:** Automatización de procesos y creación de aplicaciones, incluso para desarrollo web.
- **Educación y Aprendizaje:** Una herramienta clave para aprender estadística y programación.
- **Sector Empresarial:** Empresas como Microsoft, American Express, HP y Ford utilizan y promueven el uso de R en sus operaciones.

### Capacidades Avanzadas

Además de las funcionalidades básicas, R ofrece herramientas avanzadas que permiten abordar tareas más complejas y especializadas. Estas capacidades lo convierten en una opción poderosa para proyectos innovadores y de gran impacto. Algunos ejemplos destacados incluyen:

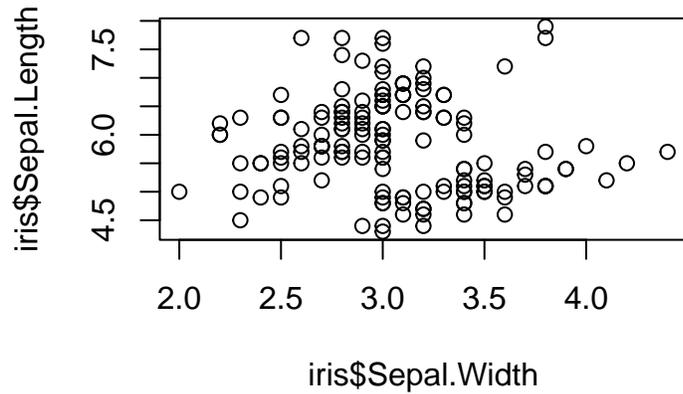
- **Aplicaciones Interactivas:** Permite desarrollar aplicaciones accesibles desde dispositivos móviles para interactuar con datos en tiempo real.
- **Análisis de Redes Sociales:** Con paquetes como 'rtweet', es posible analizar datos de plataformas como Twitter, visualizar interacciones y tendencias, y mucho más.
- **Mapas Interactivos:** Usando herramientas como 'leaflet', se pueden crear mapas dinámicos, trazar datos geoespaciales, añadir capas de información y personalizar visualizaciones.
- **Integración con Sensores de Teléfono:** Mediante aplicaciones como "Sensor Data" (Android) o "SensorLog" (iOS), puedes recopilar datos de los sensores de tu dispositivo móvil y analizarlos directamente en R.

## Ejemplos

### Gráficos

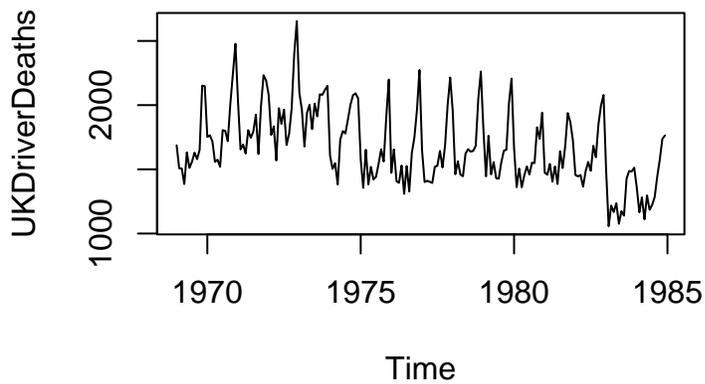
Diagrama de Dispersión:

```
plot(iris$Sepal.Width, iris$Sepal.Length)
```



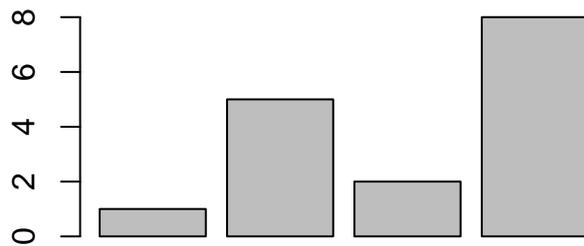
Serie temporal:

```
plot(UKDriverDeaths)
```

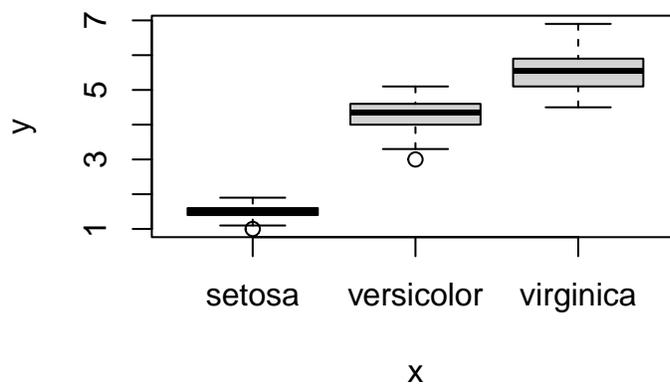


**Gráfica de Barras:**

```
barplot(c(1, 5, 2, 8))
```

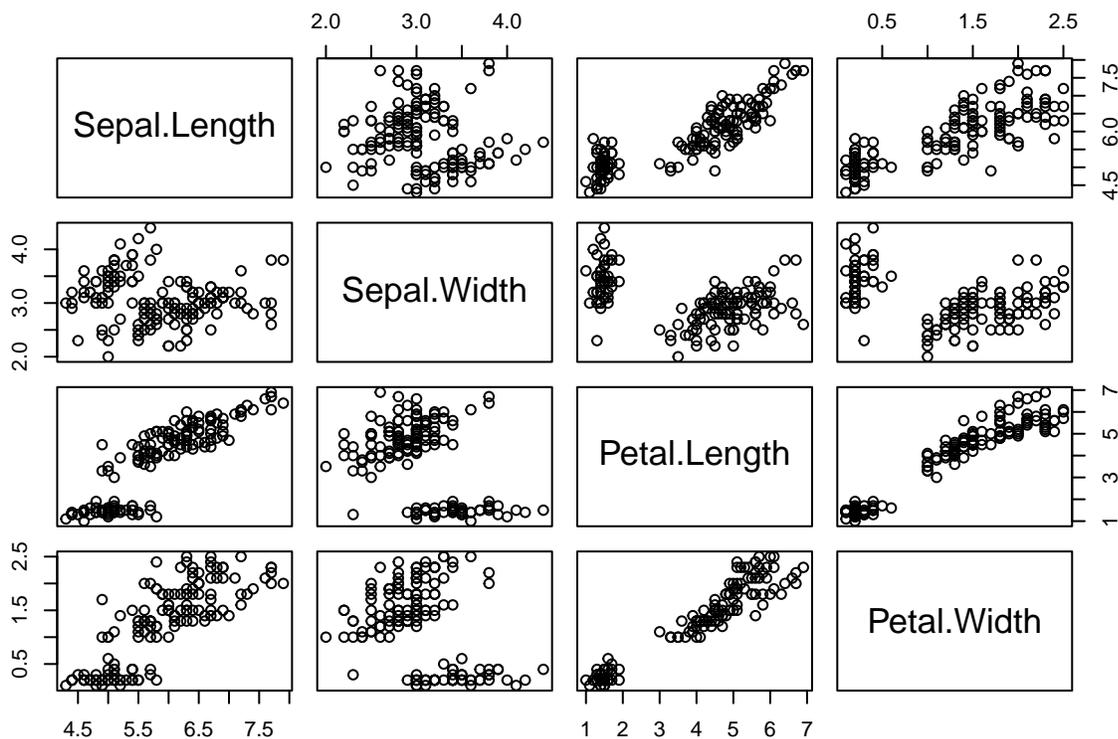
**Gráficas de cajas:**

```
plot(iris$Species, iris$Petal.Length)
```



Diagramas de dispersión emparejados:

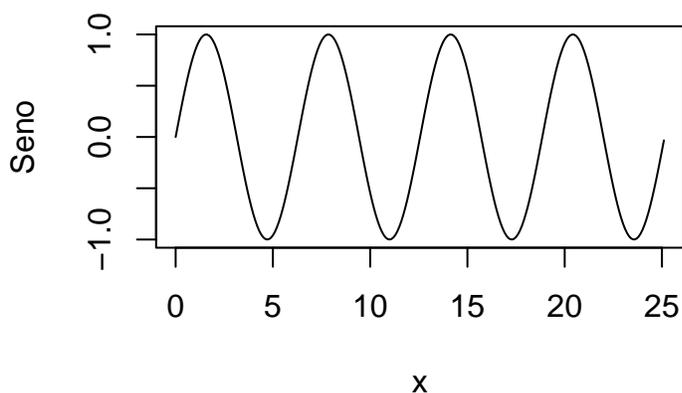
```
plot(iris[-5]) # se elimina de iris el factor con el tipo de flor
```



Gráficos personalizados

```
x <- seq(0, 8*pi, by = 0.1)
plot(x, sin(x), type = "l", xlab = "x", ylab = "Seno",
     main = "Función seno")
```

Función seno



## Gráfico de Violín

Para crear este tipo de gráficos, se pueden usar paquetes del ecosistema llamado *tidyverse* del cual se hablara más adelante.

```
library(ggplot2)
library(dplyr)

##
## Attaching package: 'dplyr'

## The following objects are masked from 'package:stats':
##
##   filter, lag

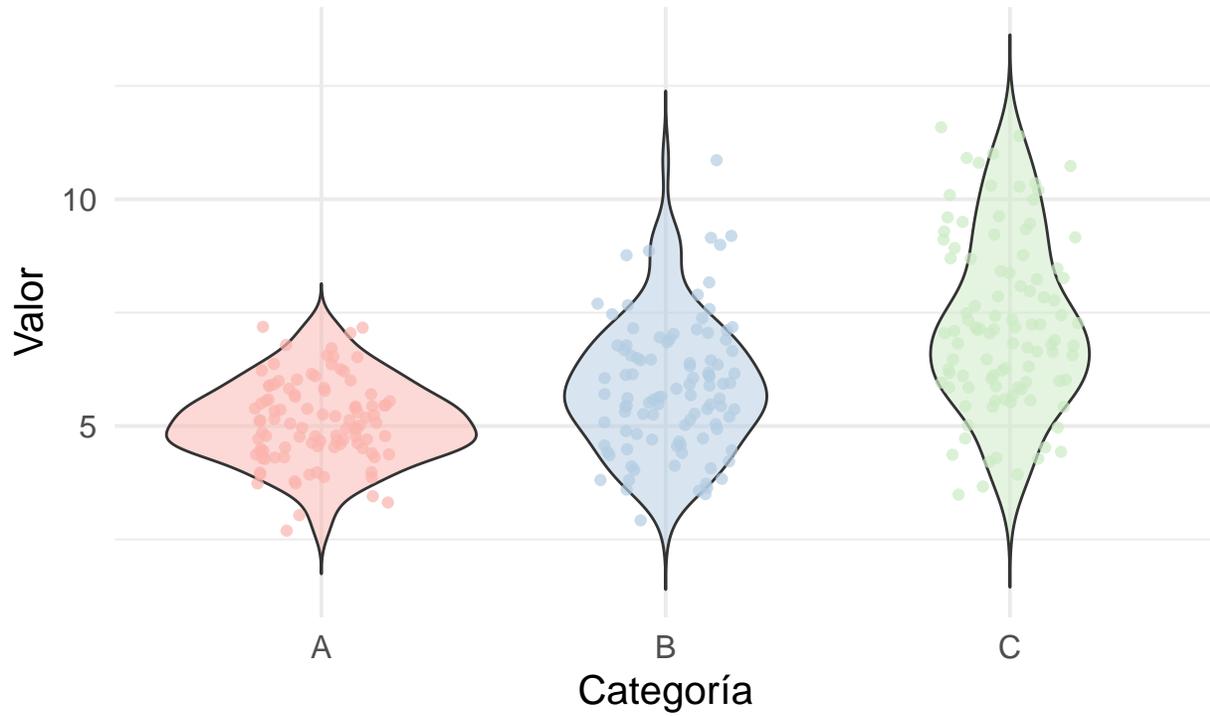
## The following objects are masked from 'package:base':
##
##   intersect, setdiff, setequal, union

set.seed(123)
data <- data.frame(
  category = factor(rep(c("A", "B", "C"), each = 100)),
  value = c(rnorm(100, mean = 5, sd = 1),
            rnorm(100, mean = 6, sd = 1.5),
            rnorm(100, mean = 7, sd = 2))
)

p <- ggplot(data, aes(x = category, y = value, fill = category)) +
  geom_violin(trim = FALSE, alpha = 0.5) +
  geom_jitter(width = 0.2, size = 1.5, alpha = 0.7, aes(color = category)) +
  labs(
    title = "Gráfico de Violín con Puntos Superpuestos",
    x = "Categoría",
    y = "Valor",
    caption = "Fuente: Datos simulados"
  ) +
  theme_minimal(base_size = 15) +
  theme(
    plot.title = element_text(hjust = 0.5),
    plot.subtitle = element_text(hjust = 0.5),
    plot.caption = element_text(hjust = 1),
    legend.position = "none"
  ) +
  scale_fill_brewer(palette = "Pastell1") +
  scale_color_brewer(palette = "Pastell1")

# Mostrar la gráfica
print(p)
```

## Gráfico de Violín con Puntos Superpuestos



Fuente: Datos simulados

## Gráfico de líneas

```
library(ggplot2)
library(dplyr)

set.seed(123)
date_seq <- seq(as.Date("2023-01-01"), by = "month", length.out = 12)
data <- data.frame(
  date = rep(date_seq, 3),
  value = c(cumsum(rnorm(12, mean = 5, sd = 2)),
            cumsum(rnorm(12, mean = 7, sd = 2)),
            cumsum(rnorm(12, mean = 6, sd = 2))),
  category = factor(rep(c("A", "B", "C"), each = 12))
)

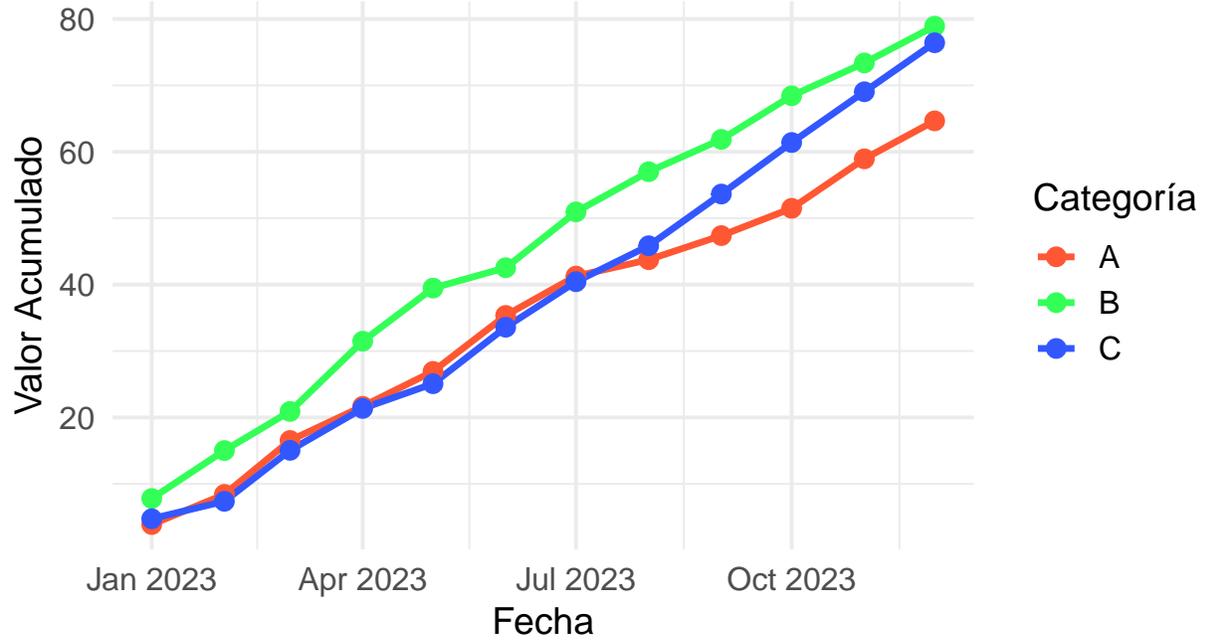
p <- ggplot(data, aes(x = date, y = value, color = category, group = category)) +
  geom_line(size = 1.2) +
  geom_point(size = 3) +
  labs(
    title = "Tendencia Temporal de Múltiples Series",
    subtitle = "Ejemplo de visualización de datos temporales con ggplot2",
    x = "Fecha",
    y = "Valor Acumulado",
    color = "Categoría",
    caption = "Fuente: Datos simulados"
  ) +
  theme_minimal(base_size = 15) +
  theme(
    plot.title = element_text(hjust = 0.5, size = 20, face = "bold"),
    plot.subtitle = element_text(hjust = 0.5, size = 16),
    plot.caption = element_text(hjust = 1, size = 12),
    axis.title = element_text(size = 14),
    axis.text = element_text(size = 12),
    legend.title = element_text(size = 14),
    legend.text = element_text(size = 12)
  ) +
  scale_color_manual(values = c("A" = "#FF5733", "B" = "#33FF57", "C" = "#3357FF"))
```

```
## Warning: Using 'size' aesthetic for lines was deprecated in ggplot2 3.4.0.
## i Please use 'linewidth' instead.
## This warning is displayed once every 8 hours.
## Call 'lifecycle::last_lifecycle_warnings()' to see where this warning was
## generated.
```

```
print(p)
```

# Tendencia Temporal de Múltiples Series

Ejemplo de visualización de datos temporales con ggplot2



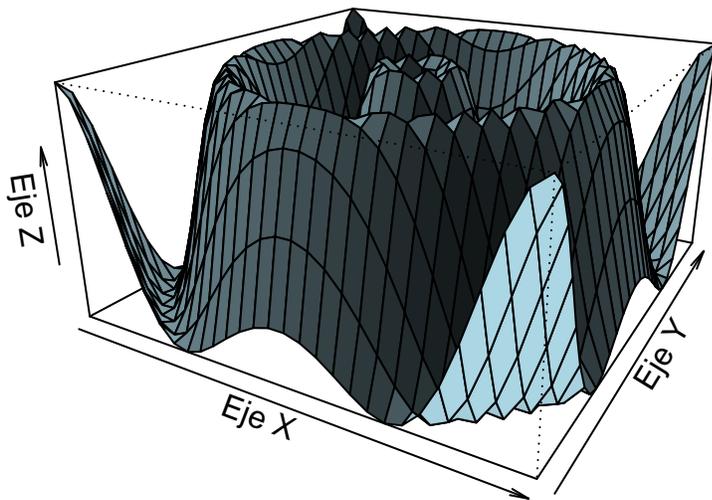
Fuente: Datos simulados

## Gráfico tridimensional

```
# Crear datos para la superficie
x <- seq(-10, 10, length.out = 30)
y <- seq(-10, 10, length.out = 30)
z <- outer(x, y, function(x, y) sin(sqrt(x^2 + y^2)))

# Graficar la superficie 3D
persp(
  x, y, z,
  main = "Gráfico tridimensional (persp)",
  xlab = "Eje X",
  ylab = "Eje Y",
  zlab = "Eje Z",
  col = "lightblue",
  theta = 30, # Ángulo de rotación horizontal
  phi = 20,   # Ángulo de elevación
  expand = 0.5, # Escala vertical
  shade = 0.5  # Sombras
)
```

### Gráfico tridimensional (persp)



tridimensional basada en la función  $z = \text{sen}(\sqrt{x^2 + y^2})$ .

Este gráfico muestra una superficie

## Distribuciones empíricas

Supongamos que se obtiene una distribución empírica para la variable altura de los hombres de la base de datos **medidas del cuerpo**.

Primero vamos a cargar los datos que vamos a usar:

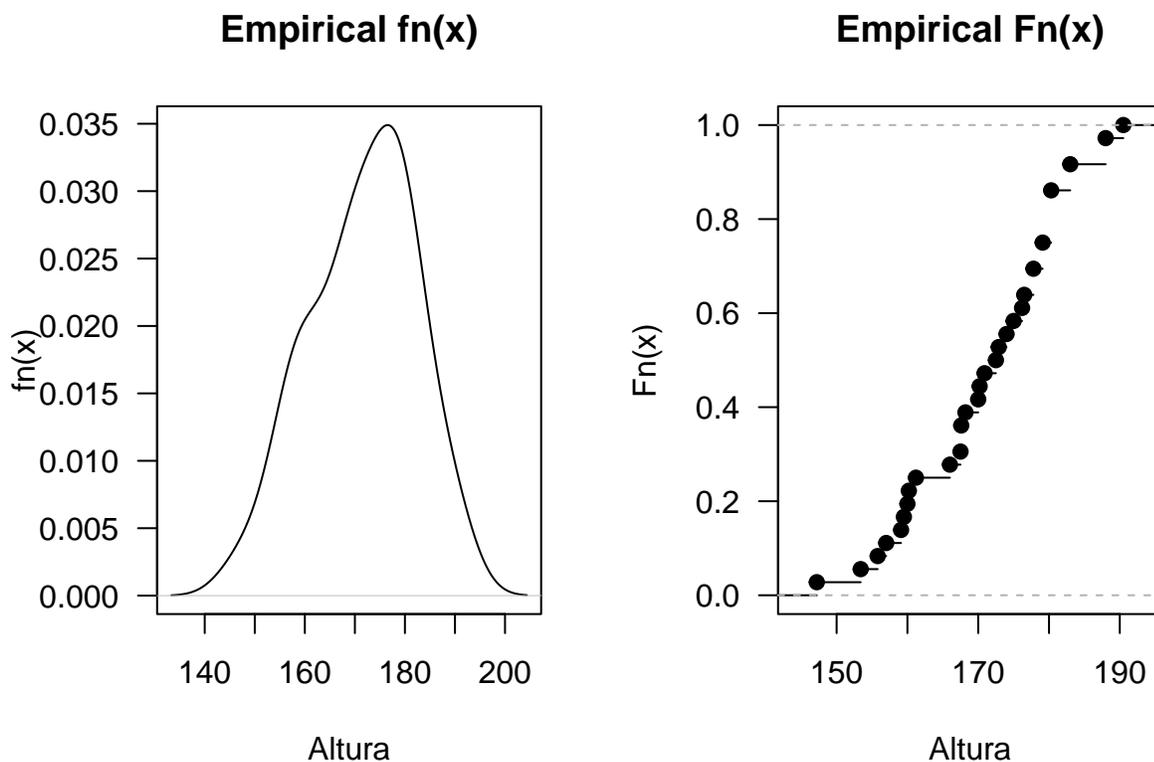
```
url <- 'https://raw.githubusercontent.com/fhernanb/datos/master/medidas_cuerpo'  
datos <- read.table(file=url, header=T)
```

### Solución

```
emp_f <- density(datos$altura)  
emp_F <- ecdf(datos$altura)
```

Ahora vamos a dibujar  $f_n(x)$  y  $F_n(x)$

```
par(mfrow=c(1, 2))  
plot(emp_f, las=1, main="Empirical fn(x)", xlab="Altura", ylab="fn(x)")  
plot(emp_F, las=1, main="Empirical Fn(x)", xlab="Altura")
```



## Intervalos de Confianza

Suponga que se quiere obtener un intervalo de confianza bilateral del 90% para la altura promedio de los hombres de la base de datos medidas del cuerpo.

### Solución

Para calcular el intervalo de confianza, primero se carga la base de datos usando la url apropiada, luego se crea un subconjunto de datos y se aloja en el objeto hombres como sigue a continuación:

```
url <- 'https://raw.githubusercontent.com/fhernanb/datos/master/medidas_cuerpo'
datos <- read.table(file=url, header=TRUE)
hombres <- datos[datos$sexo=="Hombre", ]
```

Una vez leídos los datos, se analiza la normalidad de la variable altura de los hombres, a partir de un qqPlot y un histograma

```
par(mfrow=c(1, 2))
require(car) # Debe instalar antes el paquete car
```

```
## Loading required package: car
```

```
## Loading required package: carData
```

```
##
```

```
## Attaching package: 'car'
```

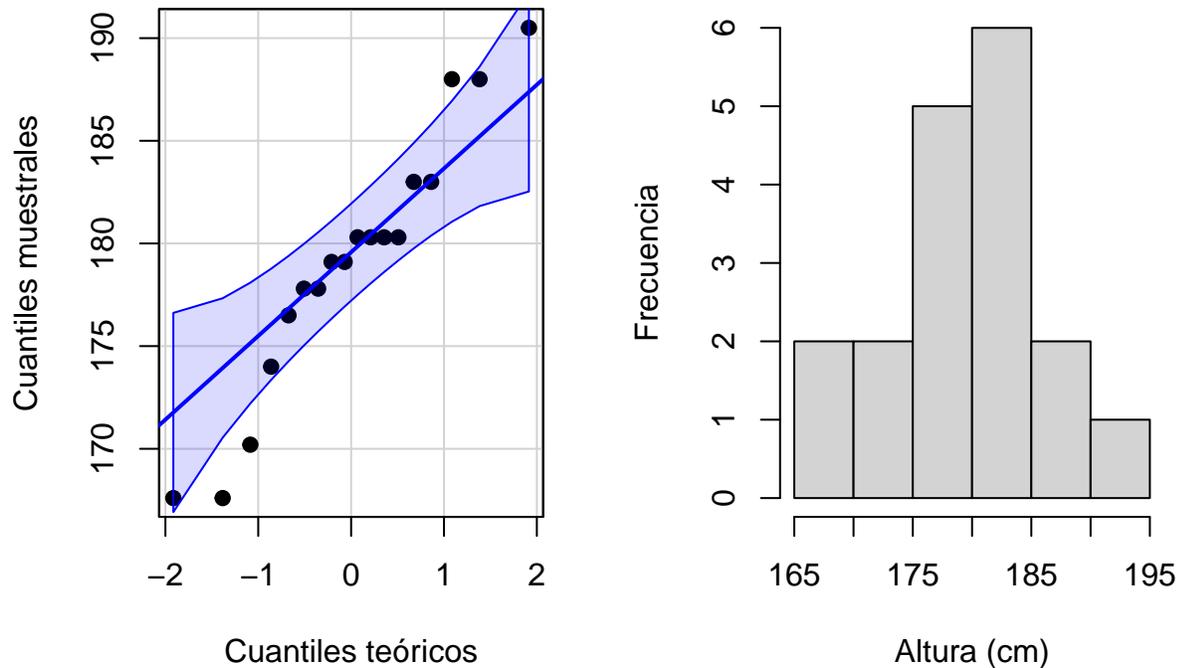
```
## The following object is masked from 'package:dplyr':
```

```
##
```

```
## recode
```

```
qqPlot(hombres$altura, pch=19, id=FALSE,
        main='qqPlot para la altura de hombres',
        xlab='Cuantiles teóricos',
        ylab='Cuantiles muestrales')
hist(hombres$altura, freq=TRUE,
      main='Histograma para la altura de hombres',
      xlab='Altura (cm)',
      ylab='Frecuencia')
```

## qqPlot para la altura de hombre! Histograma para la altura de homb



Entonces, en la respuesta se muestra el qqPlot e histograma para la variable altura, de estas figuras no se observa un claro patrón normal, sin embargo, al aplicar la prueba Shapiro-Wilk a la muestra de alturas de los hombres se obtuvo un valor-P de 0.3599, por lo tanto, se asume que la muestra de alturas proviene de una población normal.

Una vez chequeado el supuesto de normalidad se puede usar la función `t.test` sobre la variable de interés para construir el intervalo de confianza. El resultado de usar `t.test` es una lista, uno de los elementos de esa lista es justamente el intervalo de confianza y para extraerlo es que se usa `$conf.int` al final de la instrucción. A continuación se muestra el código utilizado.

```
res <- t.test(x=hombres$altura, conf.level=0.90)
res$conf.int
```

```
## [1] 176.4384 181.7172
## attr(,"conf.level")
## [1] 0.9
```

A partir del resultado obtenido se puede concluir, con un nivel de confianza del 90%, que la altura promedio de los estudiantes hombres se encuentra entre 176.4 cm y 181.7 cm.

## Capítulo 3: Abrir R por primera vez.

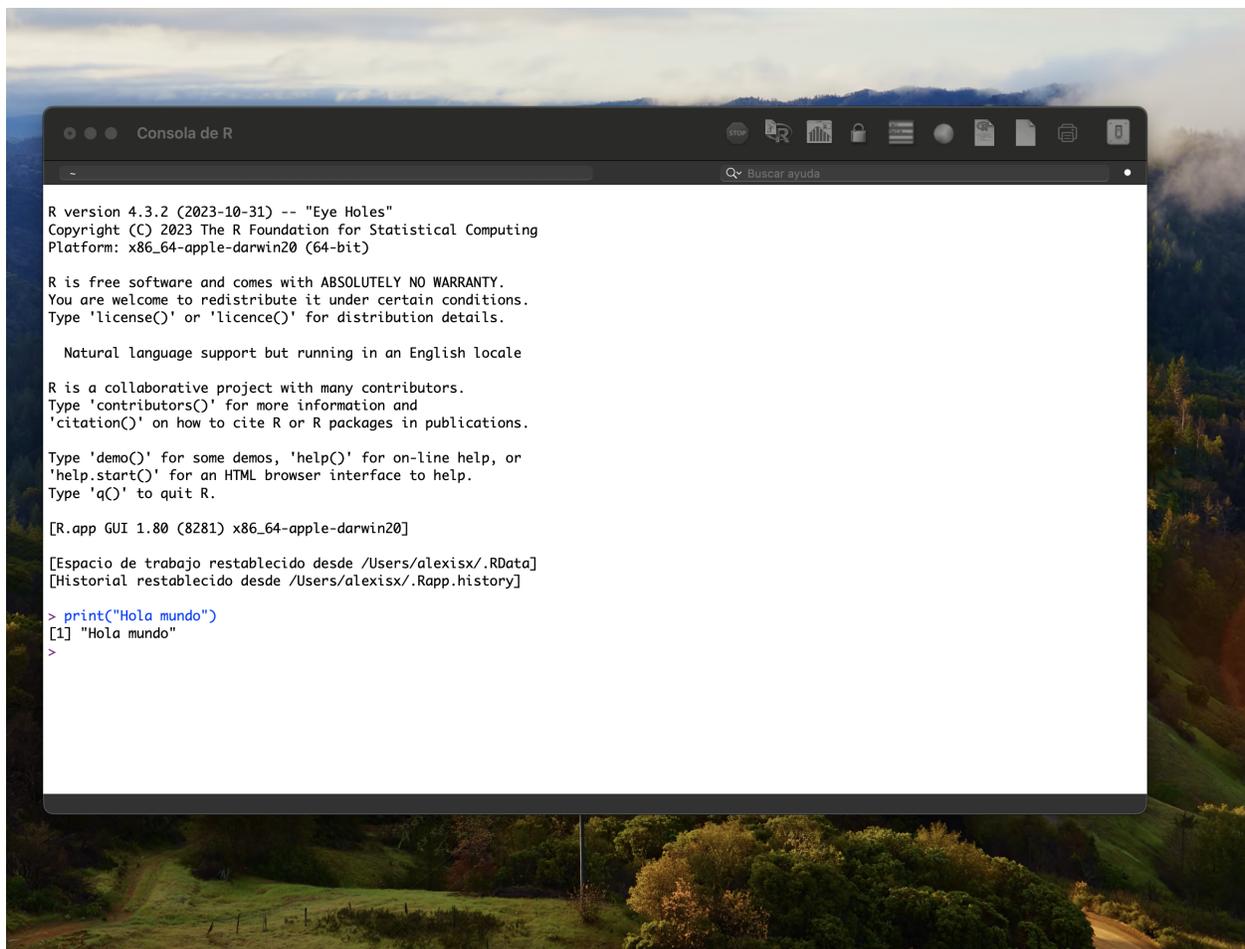
Una vez que hayamos instalado R en nuestro sistema operativo, abramos la consola y ejecutemos nuestro primer comando paso a paso.

1. Localiza donde está guardado el programa de R y ábrelo. Notese que una vez abierto nos abra una consola donde se puede empezar a escribir comandos y generar respuestas.
2. Una vez abierta la consola ejecute el siguiente comando:

```
print("Hola mundo")
```

```
## [1] "Hola mundo"
```

Note como en este ejemplo, al ejecutar la función `print()` y escribir el texto entre comillas *"Hola mundo"* la consola unicamente nos regresa el texto dentro de la función.



*Con esto empezamos nuestro camino para usar R como una herramienta :)*