UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERÍA

Tutorial del lenguaje de programación R orientado a la inteligencia de mercado

MATERIAL DIDÁCTICO

Que para obtener el título de

Ingeniero Industrial

P R E S E N T A

Diego Spamer Rivera

ASESOR DE MATERIAL DIDÁCTICO

Dr. Ricardo Torres Mendoza

Ciudad Universitaria, Cd. Mx., 2020

Tabla de contenido

Introducción

i. Antecedente

Hoy en día existen diversas fuentes digitales[1] que ofrecen cursos de programación en lenguaje R y otros orientándose al análisis de datos, el objetivo de este tutorial será proporcionar un apoyo didáctico a la materia de Inteligencia de Negocios para brindar una introducción al entorno y lenguaje R, así como la interfaz gráfica RStudio, el uso de paquetes adicionales y análisis de datos.

ii. Objetivo

El objetivo de este tutorial será brindar una introducción al entorno y lenguaje R, se podrá familiarizar con el lenguaje R, así como la interfaz gráfica RStudio, el uso de paquetes adicionales y análisis de datos.

Se buscará sentar una base sólida para que una vez terminado el tutorial exista una clara idea de cómo plantear un problema de análisis de datos y empezar a resolverlo usando el lenguaje de programación R como herramienta, así mismo se incentiva la búsqueda individual de resultados y la solución de problemas, errores en el script con el uso de plataformas digitales como Stack Overflow.[2]

iii. Contenido

Los temas que se cubrirán con este tutorial son:

1. Notas del programador
2. Introducción al análisis de datos para la Inteligencia de Negocios
    a. Conceptos clave en el análisis de datos
3. R y RStudio, instalación e introducción
    a. * R y RStudio
    b. * Tipos de Objetos
    c. * Operadores lógicos y relacionales
    d. * Bucles (Loops)

---

[1] Udemy
Analytics Vidhya
Learn R | Codecademy

[2] Stack Overflow

e. * Lectura y limpieza de Datos
f. * Bases de Datos; acceso y generación
g. * Exploración de datos
h. * Introducción a la visualización de datos

4. Casos de Estudio

1. R y Rstudio, instalación e introducción.

1.1 Definición de programa R.

R[3] es gratuito, es un ambiente de programación para cómputo estadístico y graficar datos. Como lenguaje de programación, R provee de una amplia variedad de operaciones estadísticas (modelos lineales y no lineales, pruebas estadísticas, análisis de series de tiempo, y redes neuronales por mencionar algunas) y técnicas gráficas, R es escalable, puede ser usado para pequeñas líneas de código hasta para elaborar gráficas y tableros basados en planteamientos particulares del problema de una manera sencilla para quienes están familiarizados con algún ambiente de programación.

Como medio ambiente de programación y siendo orientado al análisis estadístico, R permite manipular datos, realizar cálculos y graficar dinámicamente[4].

1.2 Rstudio

Rstudio[5] es un ambiente integrado de desarrollo, IDE por sus siglas en inglés. En este ambiente integrado, es posible visualizar los objetos con los que se trabaja en R que puede ser una tabla de datos, una conexión a una base de datos, o un modelo estadístico. Rstudio permite al programador interactuar y hacer interactuar a estos objetos a través de comandos de R.

Términos básicos en R y Rstudio

Espacio de Trabajo, es el actual ambiente de R e incluye cualquier objeto definido por el usuario (Vectores, matrices, data frames, listas, funciones). Al finalizar una sesión el usuario podrá guardar una imagen del actual *espacio de trabajo* y se cargará la siguiente vez que se inicie R.

IDE Rstudio El ambiente integrado de desarrollo (IDE), está dividido en 4 ventanas que se integran para manejar los objetos dentro del espacio de trabajo y desarrollar modelos,

[3] R: What is R?
[4] https://simplystatistics.org/2018/07/12/use-r-keynote-2018/
[5] Download RStudio | The Popular Open-Source IDE from Posit
Download RStudio | The Popular Open-Source IDE from Posit

gráficos y tableros interactivos con R: (Ver figura 1.1)

1. Source Editor .- Ventana donde están escritos los comandos, se editan los scripts de R, Rstudio ofrece autocompletar cuando se presiona la tecla tabulador.
2. R Console.- Ventana donde se indica una instrucción y se recibe una respuesta de forma interactiva; escribir instrucción, pulsar enter y recibir el resultado.
3. Environment.- Ver variables, valores y objetos cargados en RStudio, permite conocer datos cargados y conexiones a bases de datos.
4. Explorador.- Ver archivos, gráficas, referencias de las librerías, la carpeta o directorio de trabajo,paquetería instalada y ayuda.

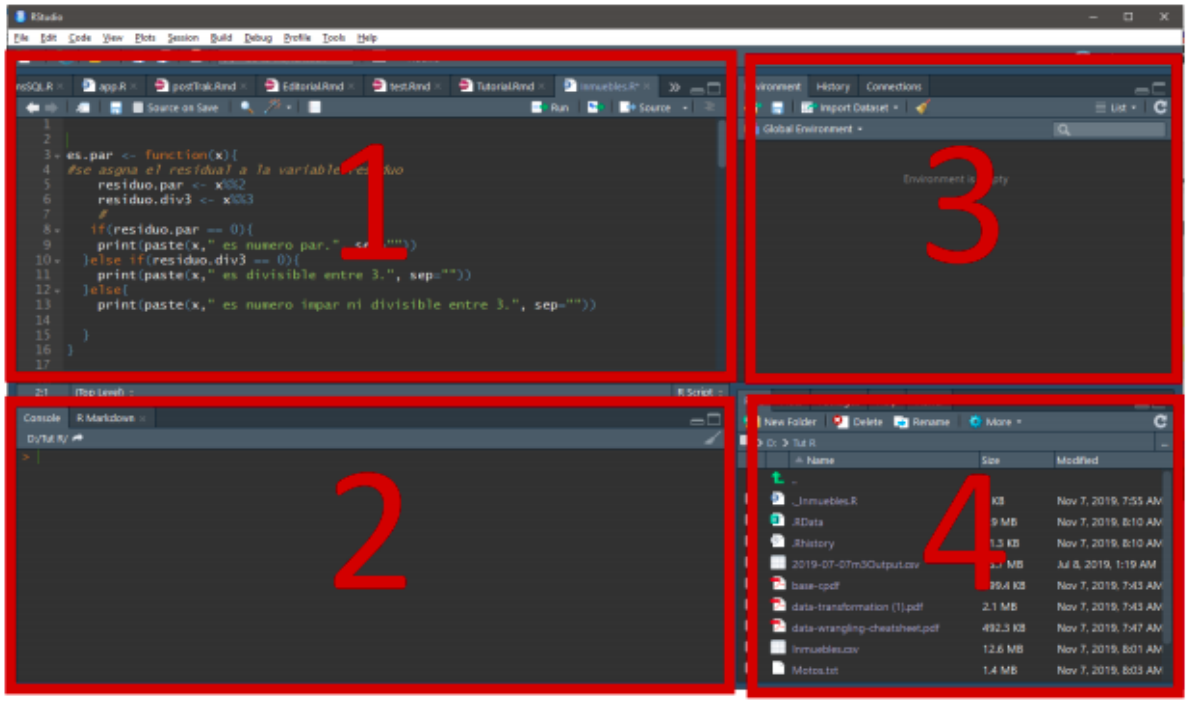

(Ver figura 1.1) Distribución de las 4 ventas descritas.

> Prompt

Con el símbolo “>” , la consola indica que está lista para ejecutar un comando.(Ver figura 1.2)

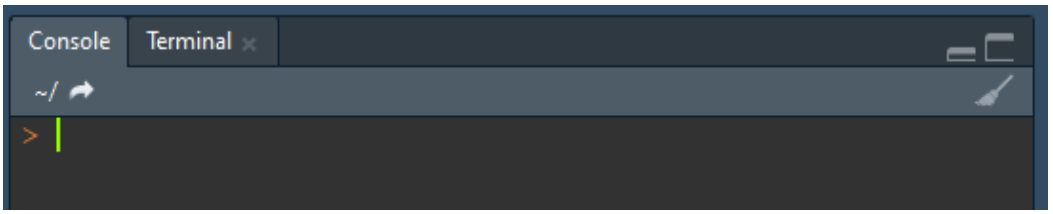

(Figura 1.2) Se observa el cursor como una línea verde.

Con el símbolo “+” , la consola indica que está esperando más argumentos o comandos.(Ver figura 1.3)

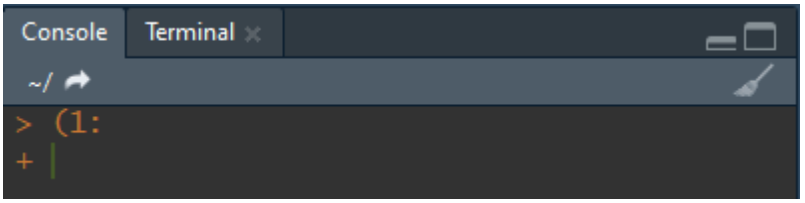

(Figura 1.3) Ahora al inicio de la línea se observa el símbolo “+” seguido del cursor. Directorio de trabajo o working directory es la carpeta en la cual “trabaja” R, esto quiere decir que es la carpeta en donde R va a leer o escribir archivos. Para conocer la ruta de nuestra computadora, se emplea el siguiente comando: (Ver figura 1.4)

```
getwd()
```

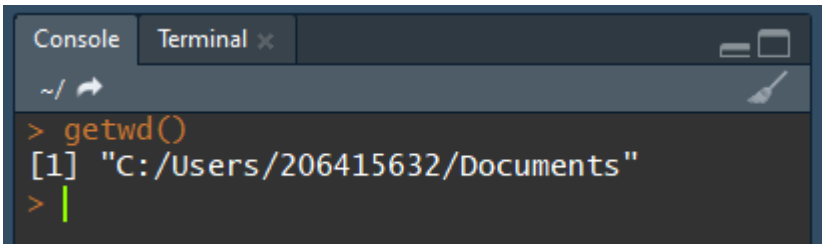

(Figura 1.4) El resultado es la ruta del sistema operativo desde el disco duro.

Para definir una ruta diferente se usa el siguiente comando:(Ver figura 1.5)

```
setwd()
```

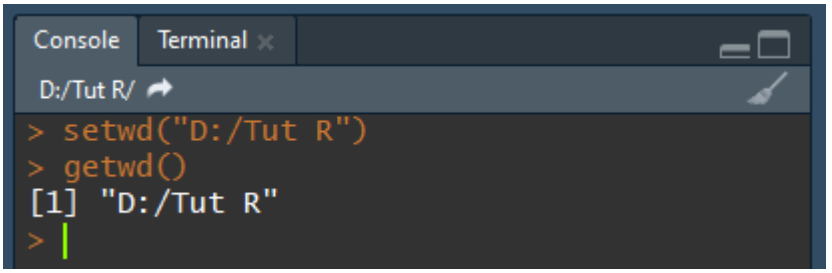

(Figura 1.5) Se vuelve a escribir el comando getwd() para comprobar la nueva ruta.

Escribiendo “getwd()” se obtiene la dirección del directorio de Windows en el que R está trabajando.

Cambiar directorio de trabajo

En la interfaz gráfica de RStudio se realiza lo siguiente:
Identificar en R estudio la ventana del explorador:

Dar clic en los 3 puntos mostrados arriba para mostrar el explorador de archivos:(Ver figura 1.6)

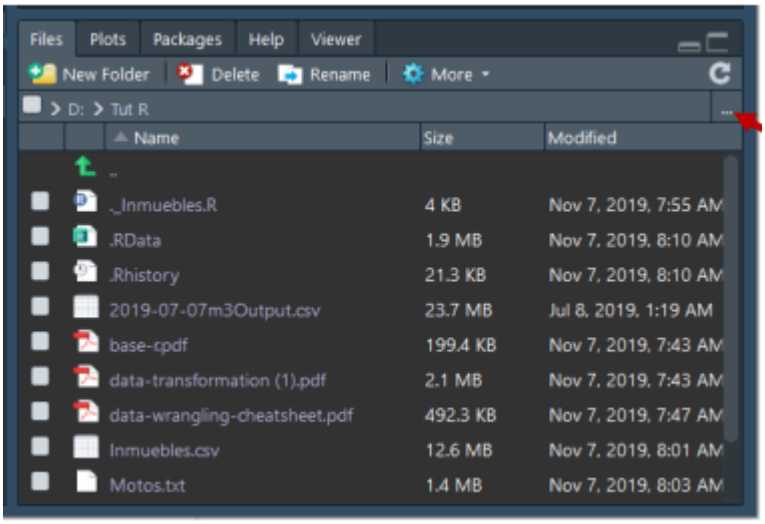

(Figura 1.6) Señalados con la flecha roja.

Seleccionar la carpeta donde están los archivos con los que se trabajará y dar clic en OK. (Ver figura 1.7)

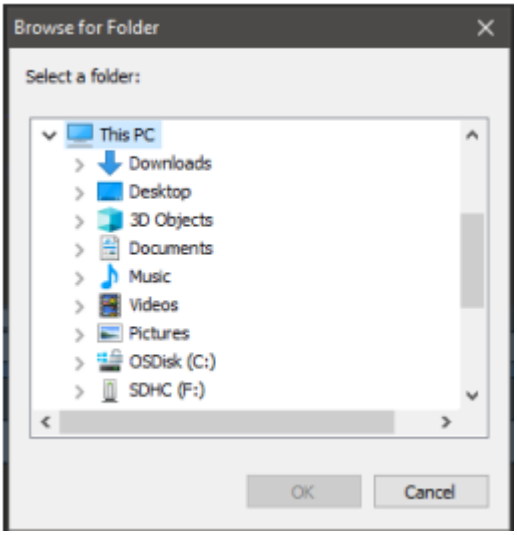

(Figura 1.7) Navegador en windows.

Se observará como la ruta y los archivos que aparecen en la ventana del explorador se actualizan según el contenido de la carpeta seleccionada:(Ver figura 1.8)

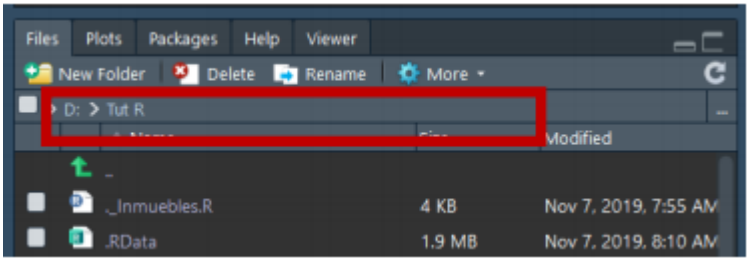

(Figura 1.8) Se marca en rojo la ruta desde el disco duro hasta el directorio de trabajo.

Dar clic en el engrane azul que dice *more*:(Ver figura 1.9)

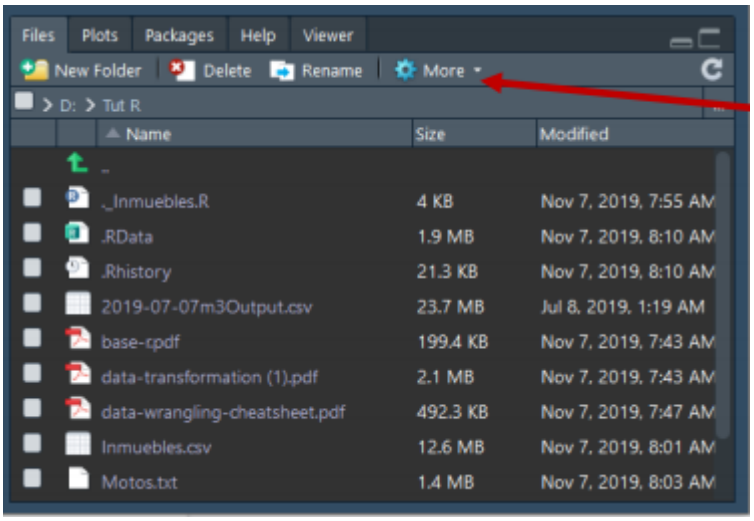

(Figura 1.9) Este engrane está en la primer pestaña de la ventana del explorador.

Elegir la opción Set As Working Directory:(Ver figura 1.10)

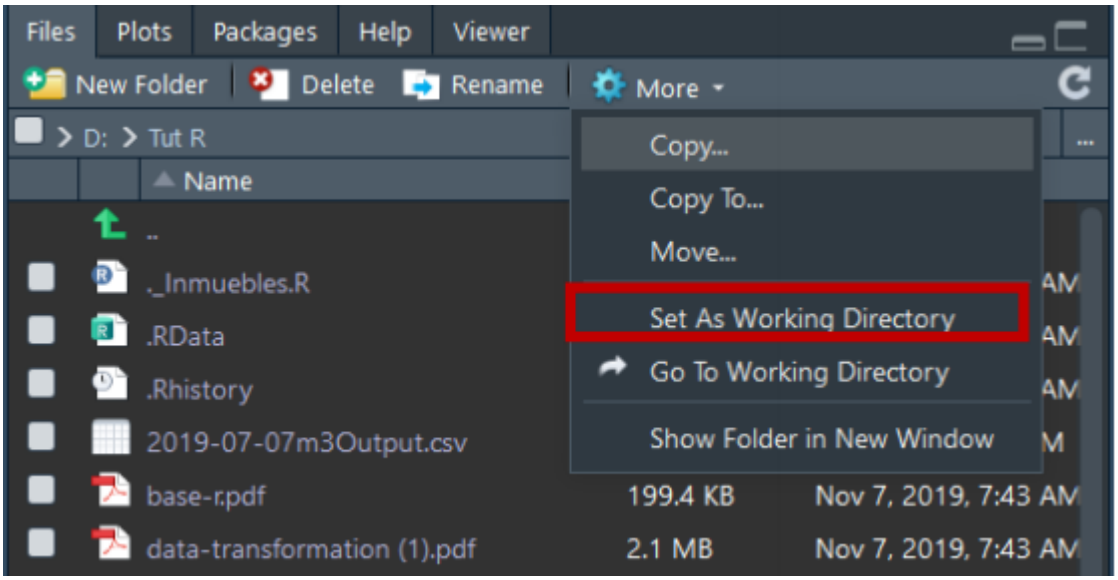

(Figura 1.10)Menú una vez hecho clic en el engrane.

Verificar en la consola que efectivamente se haya cambiado el directorio de trabajo, se escribe el comando `getwd ()` en la
consola de R:(Ver figura 1.11)

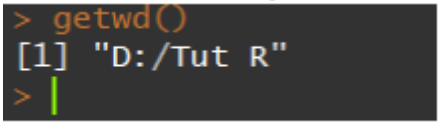

(Figura 1.11) Se vuelve a comprobar el nuevo directorio de trabajo.

1.3 Instalación de paquetes

Un paquete de R es una colección de funciones, datos y documentación que extiende las capacidades de base R, todas las librerías y paquetes pueden consultarse en el CRAN[6], también pueden hacerse instalaciones desde Github[7], al ser software abierto, muchas personas en distintos lugares pueden colaborar, esto acelera el desarrollo de software.

Como ejemplo, instalaremos la librería Tidyverse[8]. Los paquetes de Tidyverse comparten filosofía con la programación en R, y están diseñados para trabajar juntos de manera natural.

Una vez teniendo instalado R y R Studio, se podrá instalar esta paquetería, será necesario escribir lo siguiente en la consola de R:(Ver figura 1.12)

```
install.packages("tidyverse")
```

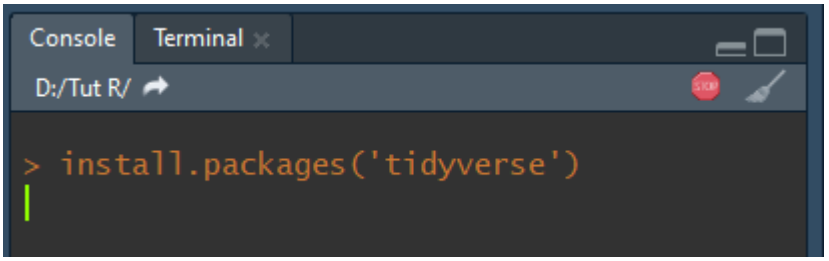

(Figura 1.12)Note que pueden ser usadas las comillas dobles " o comilla simple ' .

Cada vez que vayamos a crear un script que ocupe comandos de Tidyverse tendremos que cargar la librería con la siguiente función:(Ver figura 1.13)

```
library(tidyverse)
```

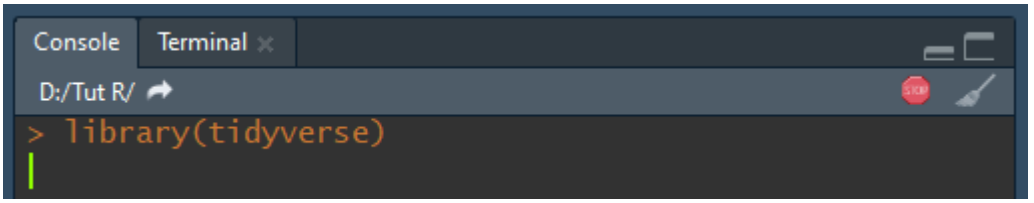

(Figura 1.13)Al cargar la librería podrán ser usadas las funciones contenidas en ella.

Comentarios

Para poder hacer notas entre líneas de código, basta con iniciar con #.
En la sección de abajo hay un par de ejemplos. ¿cuáles líneas son código y cuáles comentarios? (Ver figura 1.14)

[6] The Comprehensive R Archive Network
[7] Trending R repositories on GitHub today
[8] Tidyverse

```
#Calculate 3 + 4
3 + 4
#Calculate 6 + 12
6 + 12
```

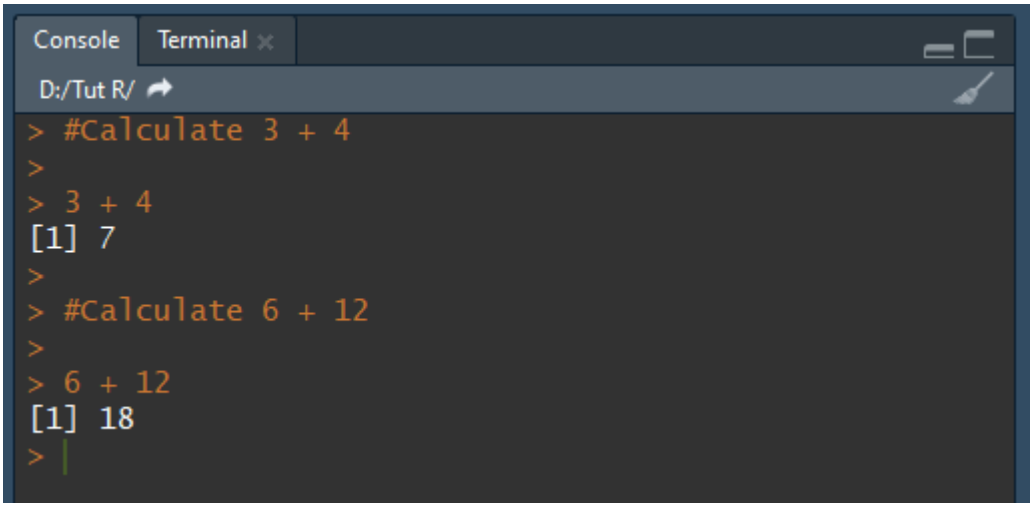

(Figura 1.14) Al escribir una línea y presionar enter, se observa que con el comentario no regresa nada la consola mientras que con la suma, la consola regresa el resultado.

1.4 Aritmética con R

En su forma más básica, R puede ser usado como una calculadora. Se consideran los siguientes Operadores Aritméticos.

- Suma: +
- Resta: -
- Multiplicación: *
- División: /
-Exponenciación: ^
- Residuo: %%

Residuo regresa el residuo de la división del número izquierdo entre el de la derecha; 5 Residuo 3 es 2.

Escribir 2^5 en el editor para calcular 2 elevado a 5.
- Escribir 28 %% 6 para calcular 28 residuo 6.
- Nota el # para comentar líneas de código R. (Ver figura 1.15)

```
#Suma
5 + 5
#Resta
```

```
5 - 5
#Multiplicación
3 * 5
#División
(5 + 5) / 2
#Exponenciación
2^5
#Residuo
28 %% 6
```

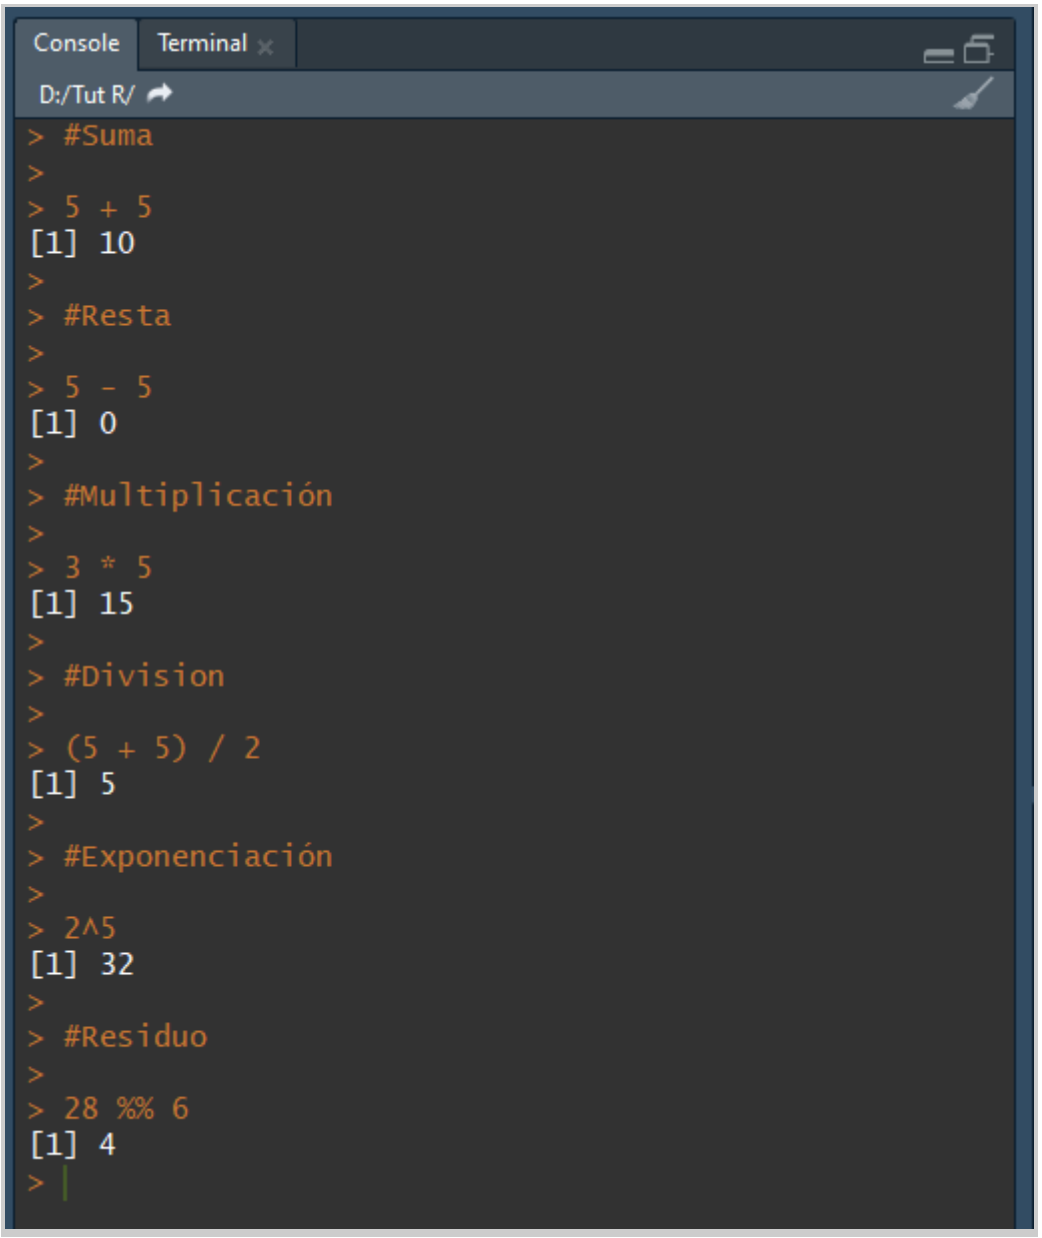

(Figura 1.15) Solución de operaciones aritméticas.

1.5 Asignación de Variables

Un concepto básico es llamado variable; una variable permite almacenar un valor dentro de un objeto en R.

Usando el nombre de la variable permite acceder a dicho valor u objeto. Con el siguiente comando se asignan variables:(Ver figura 1.16)

```
my_var <- 4
#Asignar el valor de 42 a x
x <- 42
#Imprimir el valor de variable x
x
```

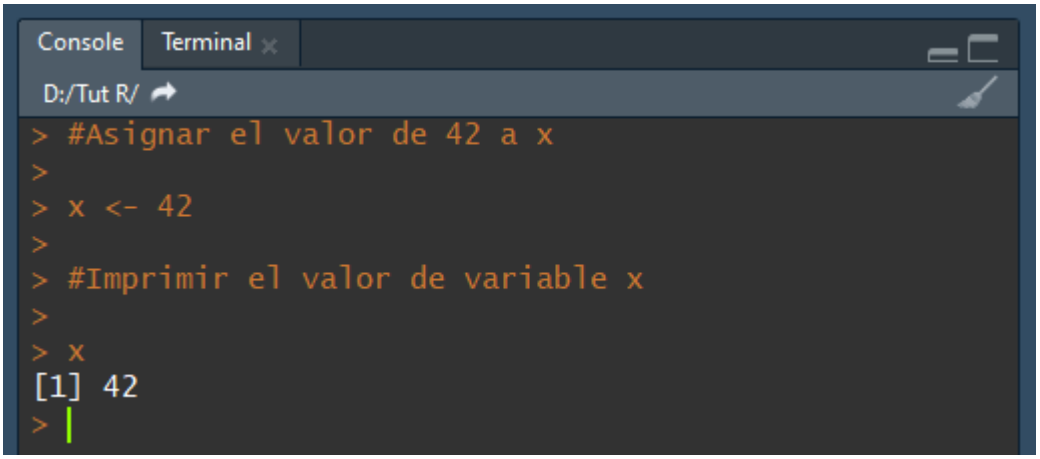

(Figura 1.16) cuando se escribe una variable, la consola imprime su valor.

1.6 Tipos de datos básicos en R

R trabaja con diversos tipos de datos, algunos de los básicos son:

- Números con decimales como 4.5 son llamados **numerics**.
- Números naturales como 4 son llamados **integers**. Integer también es numérico
- Valores booleanos como (TRUE or FALSE) son llamados **logical**.
- Texto es llamado **characters**.
- Generar una variable var_numeric y aginarle 42.
- Generar una variable var_character y asignarle "universo".

**Nota: las comillas indican que "universo" es una cadena de texto. **

- Generar una variable var_logical y asignarle FALSE.

(Ver figura 1.17)

```
#var_numeric y aginarle 42
```

```
var_numeric <- 42
#var_character  y asignarle "universo"
var_character <- "universo"
#Change variable var_logical y asignarle FALSE
var_logical <- FALSE
```

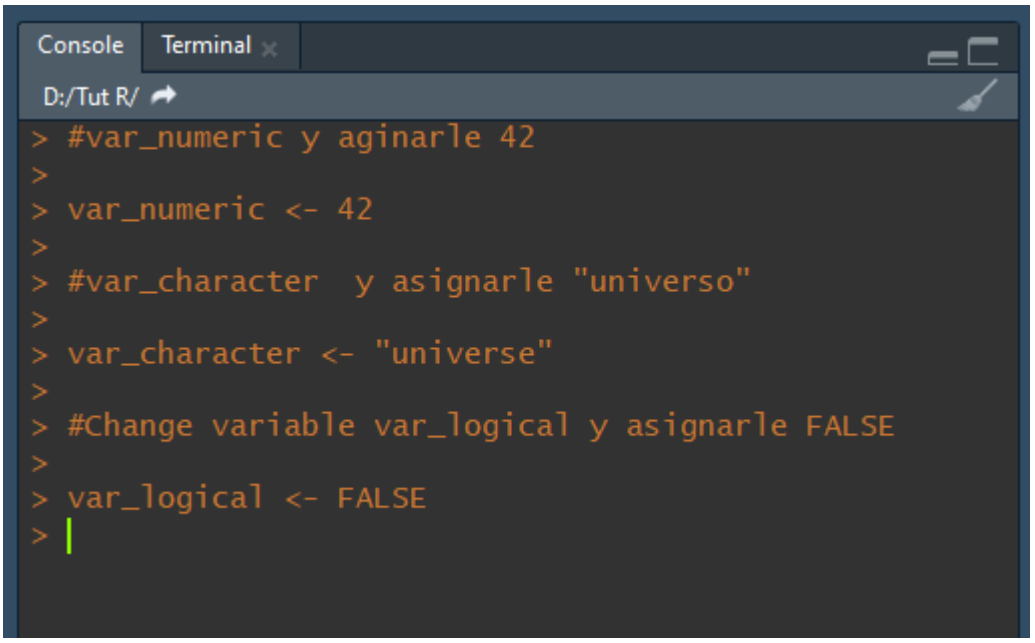

(Figura 1.17) Al asignar un valor a una variable la consola no regresa nada, solo almacena el objeto en la memoria.

1.7 Identificar tipo de datos

Si uno escribe 5 + "seis" o 5 + "Six"... (ver Figura 1.18)

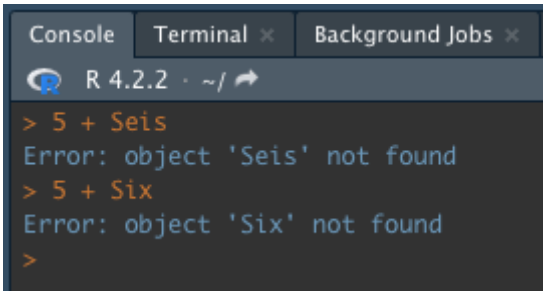

(Figura 1.18) Errores por escribir “seis” o “Six”.

...tendremos un error por una diferencia de tipos de datos en una operación. Este error puede suceder en situaciones simples o complejas.
Este error se puede evitar revisando el tipo de dato de una variable de antemano, para ello existe una función llamada class() (Ver figura 1.19)

```
#revisar clase de var_numeric
class(var_numeric)
#revisar clase de var_character
class(var_character)
#revisar clase de vary_logical
class(var_logical)
```

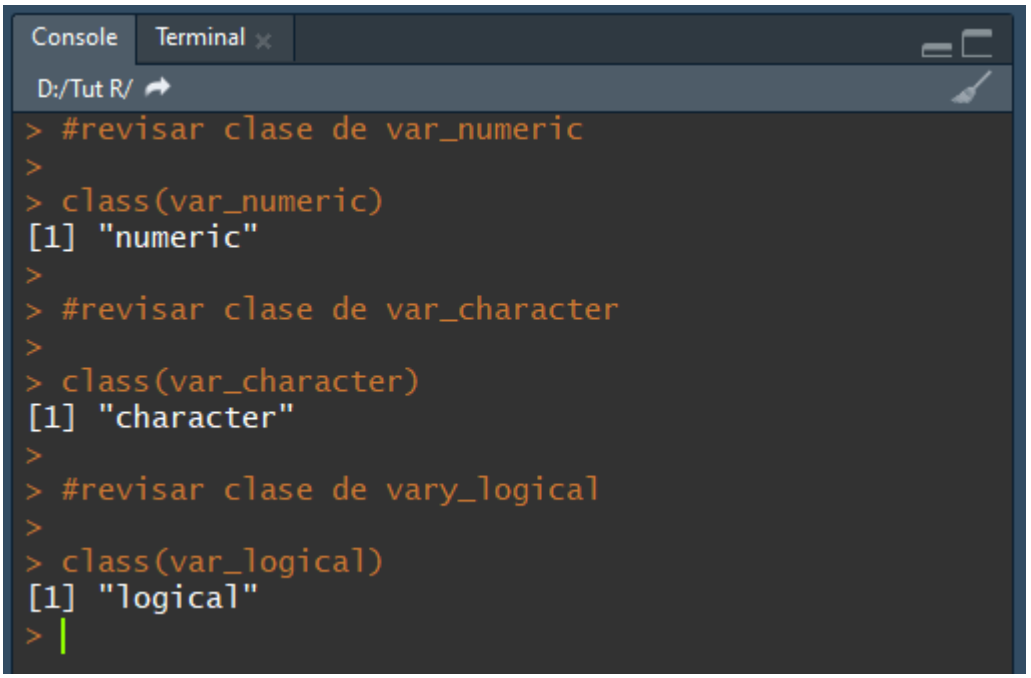

(Figura 1.19) tal como se asignó a cada variable, la consola muestra el tipo de objeto que es cada una.

1.8 Vectores

Los vectores son matrices unidimensionales que pueden contener datos numéricos, datos de caracteres o datos lógicos. En otras palabras, un vector es una herramienta simple para almacenar datos. Por ejemplo, puede almacenar sus ganancias y pérdidas diarias en los casinos.

En R, crear un vector con la función combine ** c () **. Colocar los elementos vectoriales separados por una coma entre paréntesis. Por ejemplo: (Ver figura 1.20)

```
vector_numeric <- c (1, 2, 3)
vector_character <- c ("a", "b", "c")
```

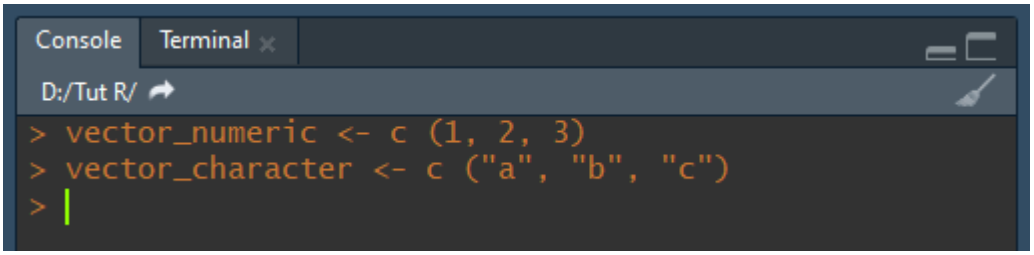

(Figura 1.20) Vector hecho con combinación de elementos.
Una vez que haya creado estos vectores en R, puede usarlos para hacer cálculos.

Generar código para un vector booleano con 3 elementos TRUE, FALSE y TRUE (en ese orden). (Ver figura 1.21)

```
boolean_vector <-c(TRUE,FALSE,TRUE)
```

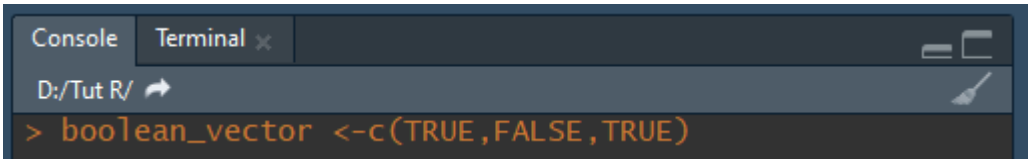

(Figura 1.22) Otra combinación de elementos para crear un vector.

Nombrar a un vector

Como analista de datos, es importante tener una visión clara de los datos que se están utilizando. Comprender a qué se refiere cada elemento es, por lo tanto, esencial.

Se puede asignar un nombre a los elementos de un vector con la función names (). Ejemplo:(Ver figura 1.23)

```
mi_vector <- c ("Juan Perez", "jugador de póker")
names (mi_vector) <- c ("Nombre", "Profesión")
```

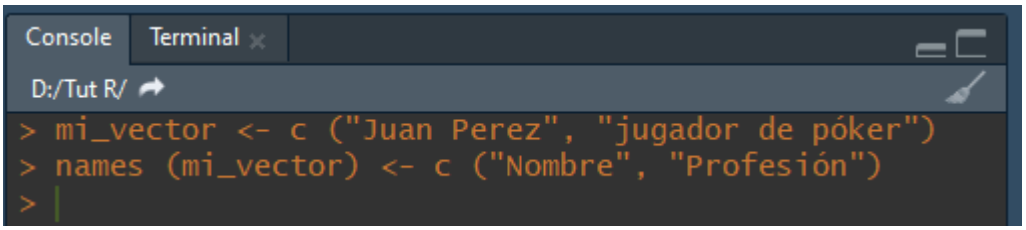

(Figura 1.23)De forma simple el nombre del vector indica que dato hay escrito.

Este código primero crea un vector mi_vector y luego le da un nombre a los dos elementos. Al primer elemento se le asigna el nombre Nombre, mientras que el segundo elemento se etiqueta Profesión. Imprimir los contenidos en la consola produce el siguiente resultado: (Ver figura 1.24)

```
mi_vector
```

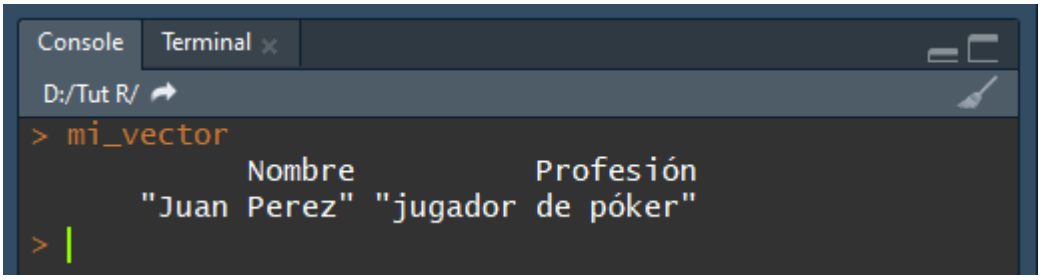

(Figura 1.24) Con los vectores nombrados se entiende la información

Para los vectores poker_vector y roulette_vector, asignarles los nombres de los días de la semana (Ver figura 1.25)

```
# Ganancias por Poker Lunes a Viernes
poker_vector <- c(140, -50, 20, -120, 240)
# Ganancias Ruleta Lunes a Viernes
roulette_vector <- c(-24, -50, 100, -350, 10)
```

```
# Assignar nombres de los días a cada uno
names(poker_vector) <- c("Monday", "Tuesday", "Wednesday",
"Thursday", "Friday")
names(roulette_vector)<- c("Monday",
"Tuesday","Wednesday","Thursday","Friday")
```

Podemos brevemente mirar la ventana de ambiente y notar como están ahí todos los objetos que hemos creado hasta este punto:

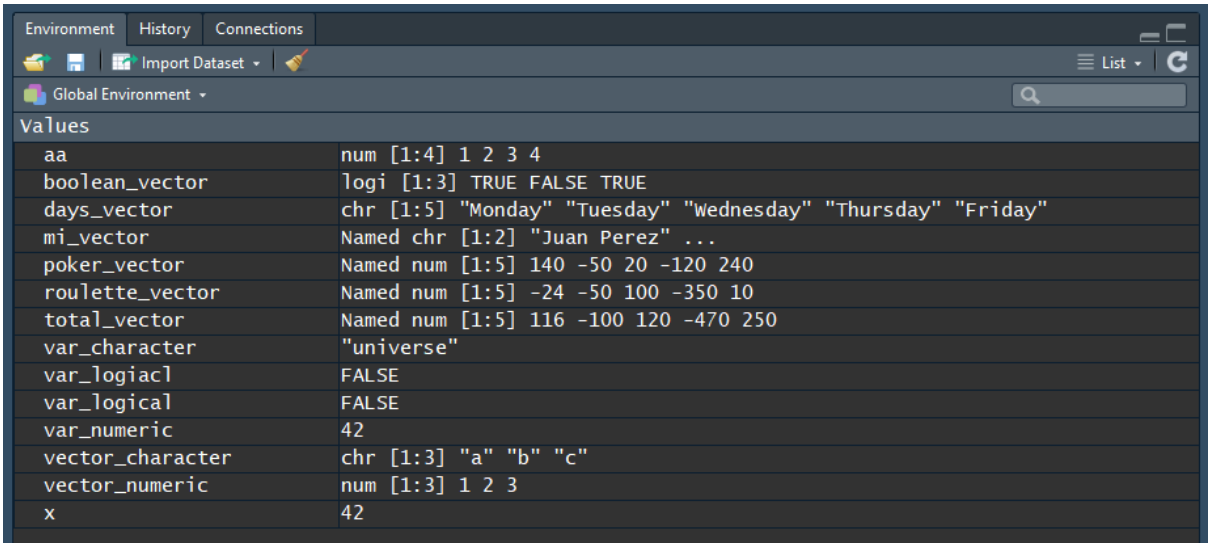

(Figura 1.25) Todos los elementos son Valores.

1.9 Cómo nombrar fácilmente una variable

En los ejercicios anteriores probablemente experimentó que es aburrido y frustrante escribir y volver a escribir información, como los días de la semana. Sin embargo, cuando se mira desde una perspectiva más alta, hay una manera más eficiente de hacer esto, a saber, asignar los vectores del día de la semana a una variable

Al igual que lo hizo con las ganancias de póker y ruleta, también puede crear una variable que contenga los días de la semana. De esta manera puedes usarlo y reutilizarlo

Generar un vector que se llame días de la semana y asignarlos como nombres de los vectores de poker y roulette(Ver figura 1.27)

```
poker_vector <- c(140, -50, 20, -120, 240)
roulette_vector <- c(-24, -50, 100, -350, 10)

# días de la semana
days_vector <- c("Monday", "Tuesday", "Wednesday", "Thursday",
"Friday")
# Asignando los nombres:
names(poker_vector) <- days_vector
names(roulette_vector) <- days_vector
```

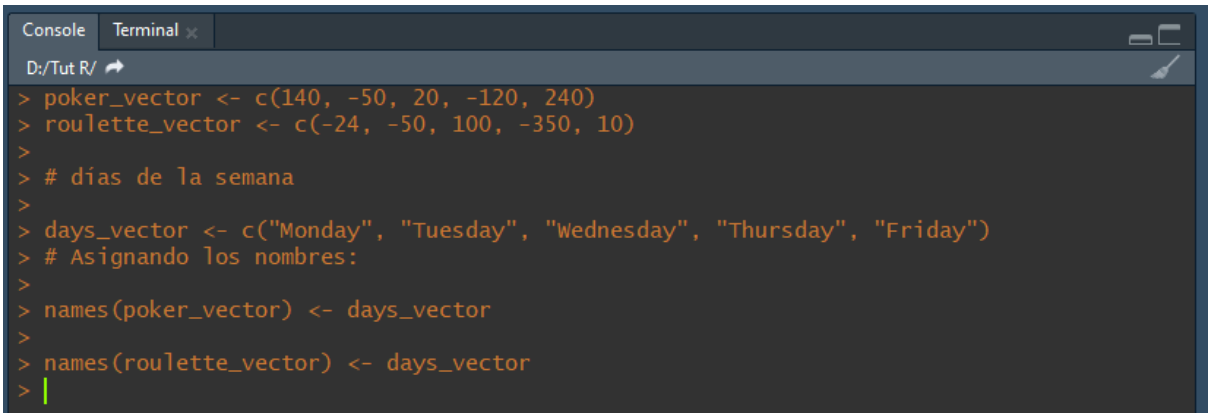

(Figura 1.27) al crear vectores la consola no imprime nada, solo los guarda en la memoria.

1.10 Calcular totales

Con las ganancias de póker y ruleta como vectores con nombre, puede comenzar a hacer algo de analítica de datos.

¿Cuánto ha sido su ganancia o pérdida general por día de la semana?
¿Ha perdido dinero durante la semana en total?
¿Está ganando / perdiendo dinero en el póker o en la ruleta?

Para obtener las respuestas, tienes que hacer cálculos aritméticos en vectores.

Es importante saber que si suma dos vectores en R, toma la suma de elementos. Por ejemplo, las siguientes tres declaraciones son completamente equivalentes (Ver figura 1.28)

```
c(1, 2, 3) + c(4, 5, 6)
c(1 + 4, 2 + 5, 3 + 6)
c(5, 7, 9)
```

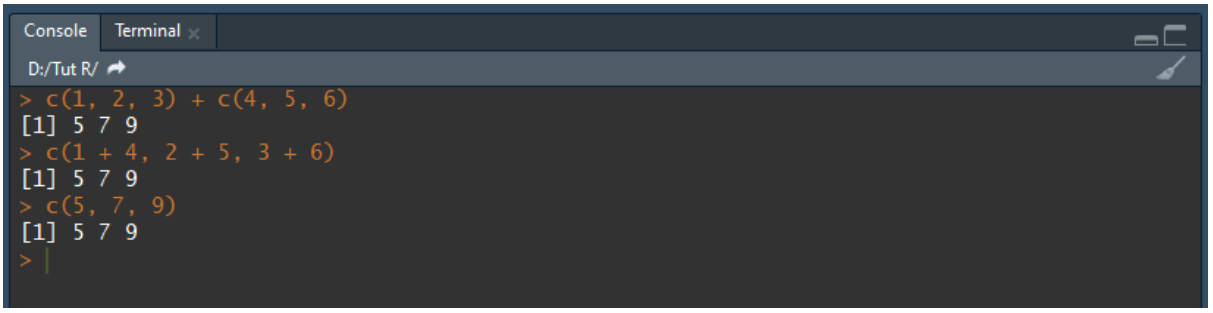

(Ver figura 1.28)

Naturalmente, esto se puede hacer con variables que representan vectores:(Ver figura 1.29)

```
a <- c(1, 2, 3)
b <- c(4, 5, 6)
c <- a + b
c
```

(Ver figura 1.29) Resultado de una suma de vectores.

¿Cuánto ha sido su ganancia o pérdida general por día de la semana?

```
total_vector <- poker_vector+roulette_vector
```

¿Ha perdido dinero durante la semana en total?

```
sum(total_vector)
```

¿Está ganando / perdiendo dinero en el póker o en la ruleta?

```
sum(poker_vector)
sum(roulette_vector)
```

(Ver figura 1.30)

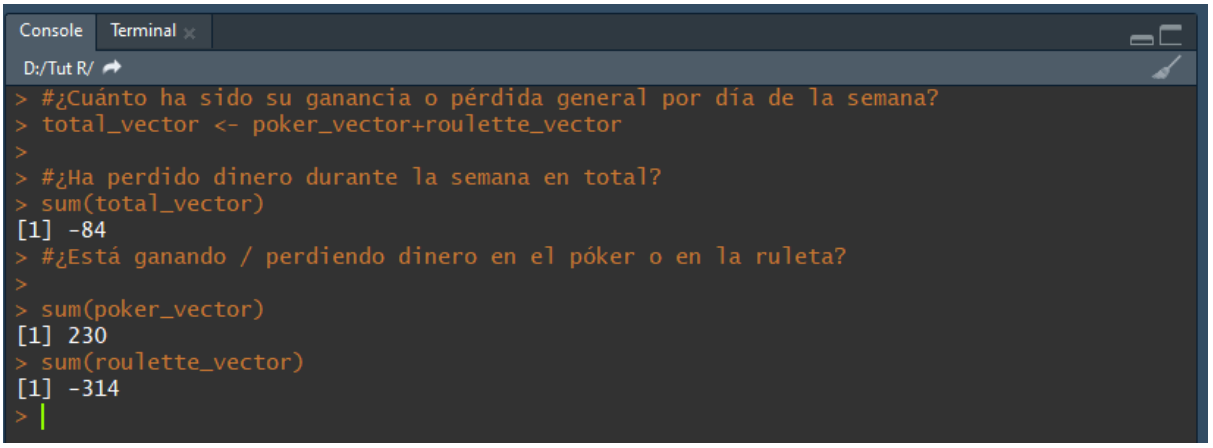

(Ver figura 1.30) Es fácil ver que hay pérdidas en la ruleta.

1.11 Selección de vectores

Para seleccionar elementos de un vector (y matrices, *dataframes* y otros objetos), puede usar corchetes. Entre corchetes, se indica qué elementos seleccionar.Por ejemplo:
Para seleccionar el primer elemento del vector, escriba poker_vector [1]. Para seleccionar el segundo elemento del vector, escriba poker_vector [2], etc.

Observe que el primer elemento en un vector tiene índice 1, no 0 como en muchos otros lenguajes de programación.

Asignar los resultados de Poker en Miércoles a la variable poker_wednesday.(Ver figura 1.31)

```
poker_vector
roulette_vector
# Definir una nueva variable
poker_wednesday <- poker_vector[3]
```

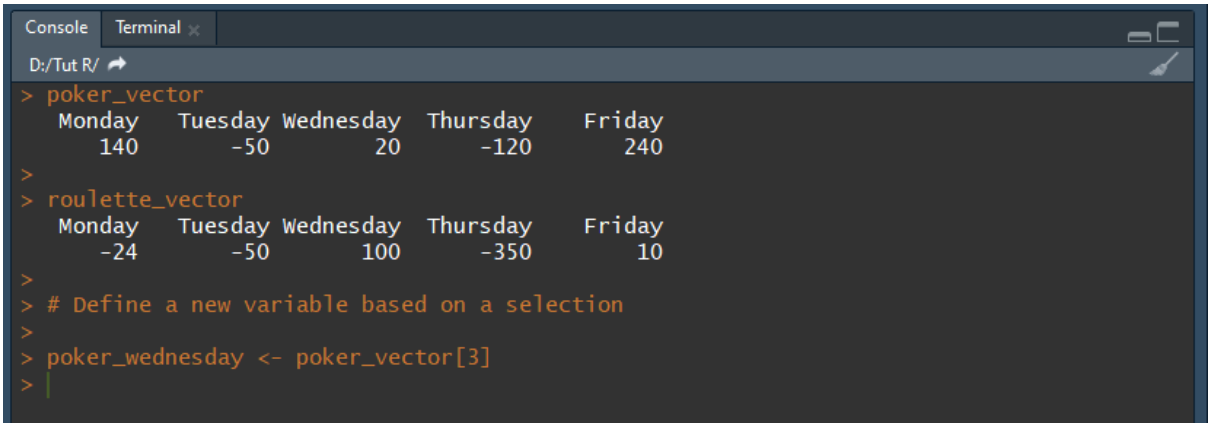

(Figura 1.31) El tercer elemento del vector Poker, es el ingreso del miércoles.

1.12 Seleccionar múltiples elementos de un vector

Para seleccionar múltiples elementos de un vector, puede agregar corchetes al final del mismo. Puede indicar entre paréntesis qué elementos deben seleccionarse. Por ejemplo: suponga que desea seleccionar el primer y el quinto día de la semana: use el vector c (1, 5) entre corchetes. Por ejemplo, el siguiente código selecciona el primer y quinto elemento de poker_vector:

```
poker_vector [c (1, 5)]
```

Asignar los resultados de póker del martes, miércoles y jueves a la variable poker_entresemana. (Ver figura 1.33)

```
poker_vector
roulette_vector

# Definiendo variable según selección
poker_entresemana <- poker_vector[c(1,2)]

poker_entresemana
```

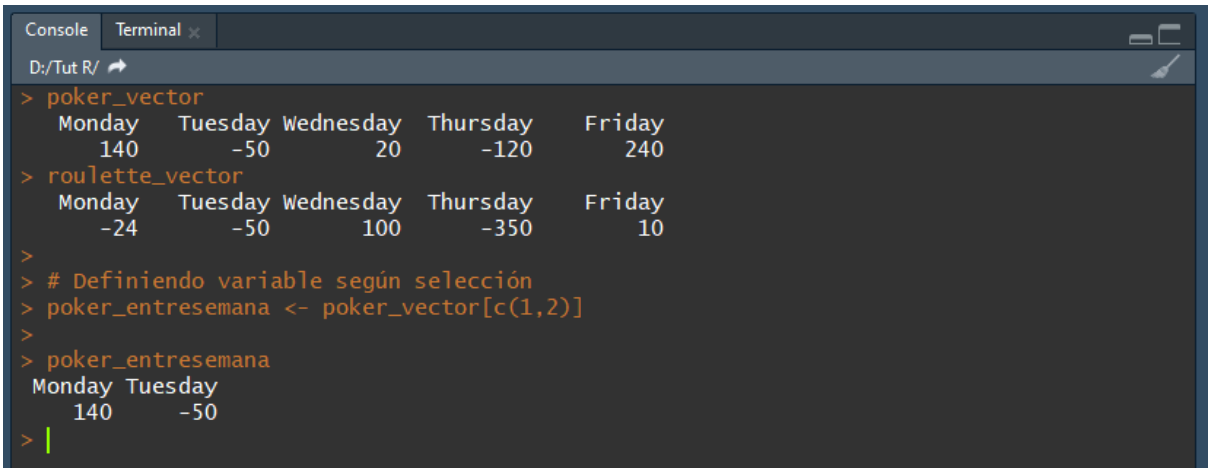

(Figura 1.33) Al haber escrito c(1,2) sólo están los datos de lunes y martes.

1.13 Seleccionar múltiples elementos de un vector (versión corta)

Seleccionar múltiples elementos de poker_vector con c (2, 3, 4) no es muy conveniente. Existe una forma más fácil de hacer esto: c (2, 3, 4) se puede abreviar a 2: 4, lo que genera un vector con todos los números naturales de 2 a 4.

Entonces, otra forma de encontrar los resultados de mitad de semana es poker_vector [2: 4]. Observe cómo se coloca el vector 2: 4 entre corchetes para seleccionar el elemento 2 hasta 4.

Asignar a roulette_selection_vector los resultados de la ruleta de martes a viernes; utiliza: si facilita las cosas.(Ver figura 1.34)

```
# Ganancias de póker y ruleta de lunes a viernes:
poker_vector
roulette_vector

# Definir una nueva variable basada en una selección
roulette_selection_vector <- poker_vector [2: 4]
```

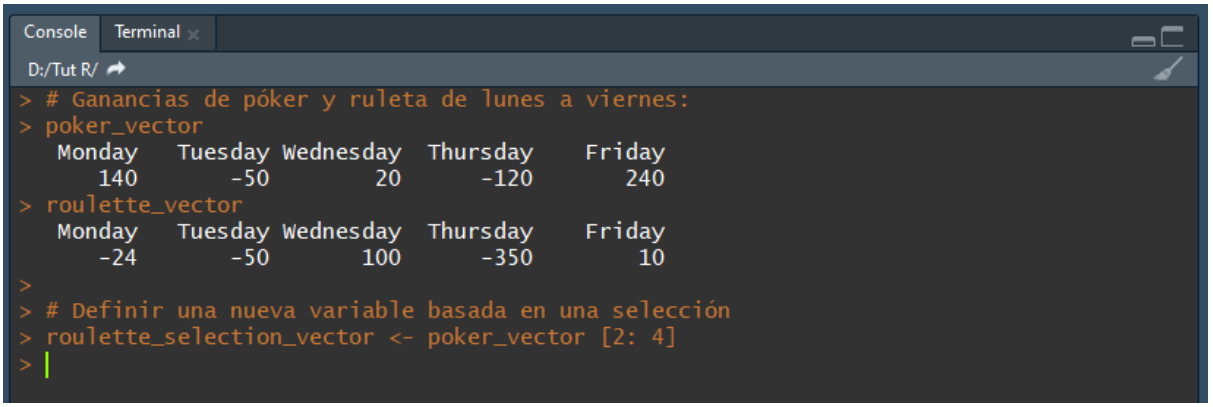

(Ver figura 1.34)

1.14 Seleccionar múltiples elementos de un vector (con nombres)

Otra forma de abordar el ejercicio anterior es mediante el uso de los nombres de los elementos del vector (lunes, martes, ...) en lugar de sus posiciones numéricas. Por ejemplo, poker_vector ["Monday"].

Se seleccionó el primer elemento de poker_vector ya que "Monday" es el nombre de ese primer elemento.

Tal como lo hizo en el ejercicio anterior con números, también puede usar los nombres de elementos para seleccionar varios elementos, por ejemplo:(Ver figura 1.35)

```
poker_vector [c ("lunes", "martes")]
```

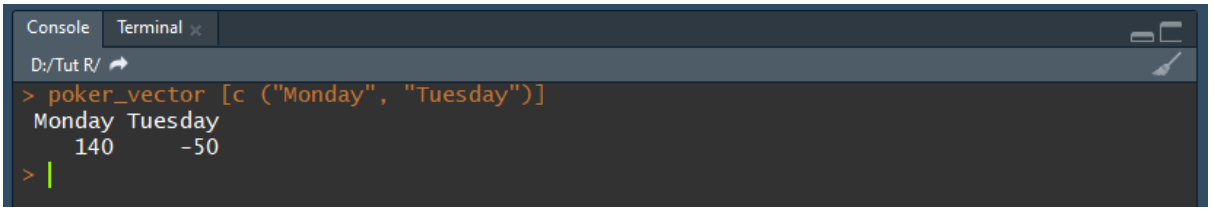

(Figura 1.35) de manera equivalente a la notación numérica, es posible elegir elementos según el nombre del vector.

Seleccionar los 3 primeros elementos de cada uno usando los nombres de las variables "Monday", "Tuesday" and "Wednesday". Asignar el valor a un nuevo vector.
Calcular el promedio de los valores con la función mean() (Ver figura 1.36)

```
# Ganancias de póker y ruleta de lunes a viernes:
poker_vector
roulette_vector

# Seleccionar resultados de poker para Monday, Tuesday and
Wednesday
poker_start <- poker_vector[c("Monday","Tuesday","Wednesday")]

# Calcular el promedio
mean(poker_start)
```

(Figura 1.36)

1.15 Operadores relacionales

Los operadores relacionales permiten observar la relación entre un objeto y otro.

- Revisar si dos objetos son iguales (==) o diferentes (!=).

- Strings
- Numbers
- logicals
- others

- Revisar si es mayor o menor con < >, >= <=.
  - En caracteres el default es orden alfabético.
  - En pruebas lógicas es True > False.

- Es posible comparar valores y vector VS vector.

Igualdad
Comparación más básica (Ver figura 1.37)

```
3 == (2 + 1)
"intermedio" != "r"
TRUE != FALSE
"Ingeniero" != "ingeniero"
```

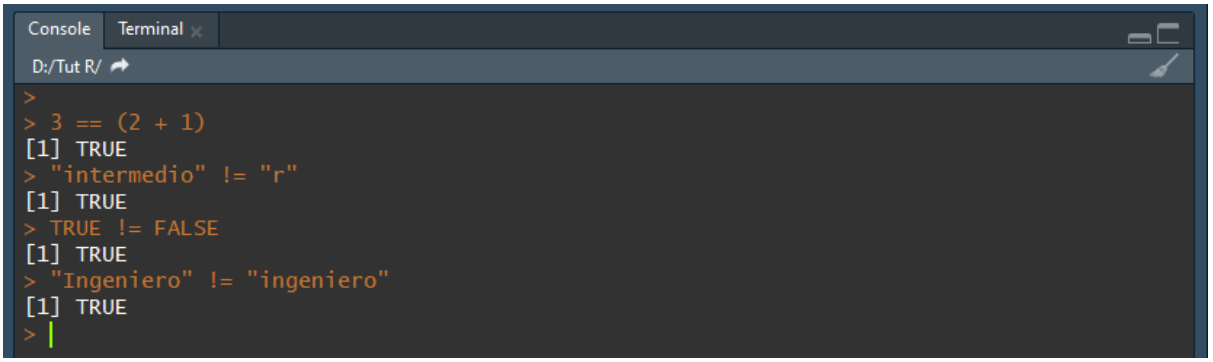

(Figura 1.37) La consola de R imprime el resultado de la evaluación de un operador lógico.

- Escribir en R si TRUE == FALSE.
- Revisar si -6 * 14 es diferente a: 17 - 101.
- Comparar cadenas de caracteres. Con R determine si "useR" y "user" son iguales.
- Descubrir que sucede si se comparan valores lógicos con números: TRUE y 1 son iguales? (Ver figura 1.38)

```
# Comparacion logica
TRUE == FALSE

# Comparacion de numeros
-6*14 != 17-101

# Comparacion de caracteres
"useR" == "user"
```

```
# Comparar valor lógico con numerico
TRUE == 1
```

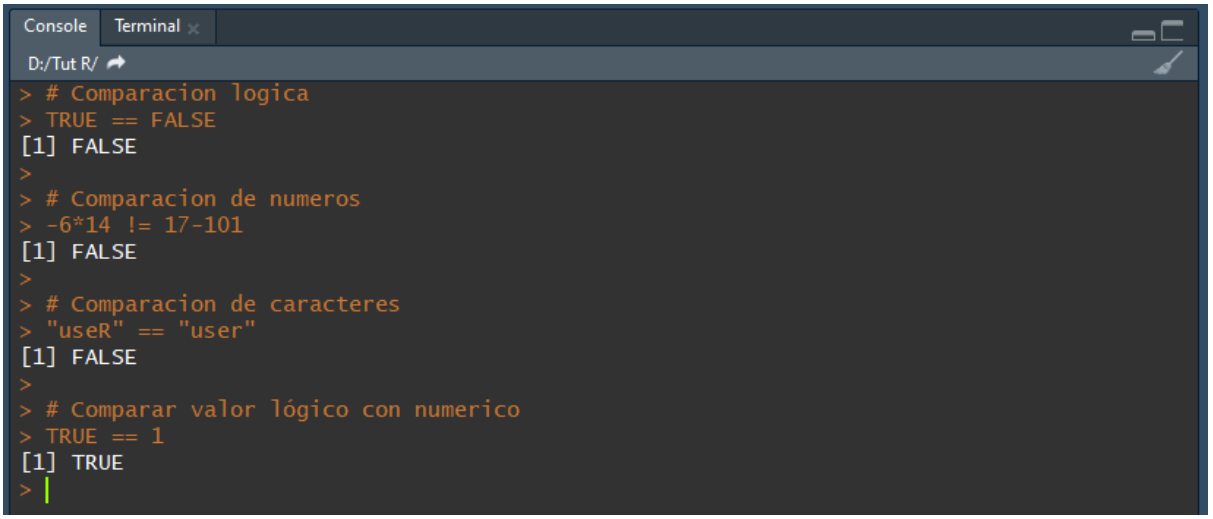

(Figura 1.38) Se puede apreciar también que R sigue la jerarquía de operaciones aritméticas.

1.16 Mayor y Menor que

Observar las siguientes expresiones en R, todas evalúan como FALSE: (Ver figura 1.39)

```
(1 + 2) > 4
"perro" < "Gatos"
TRUE <= FALSE
```

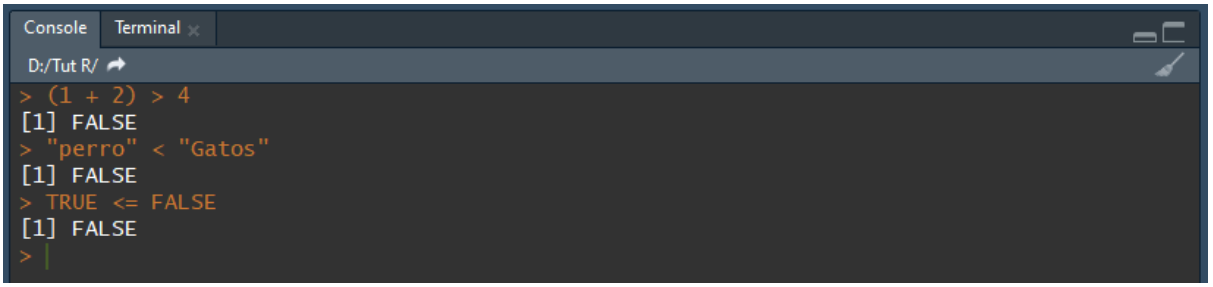

(Figura 1.39) Es posible saber si perro es mayor que Gatos.

Al comparar caracteres, R determina la relación mayor que basado en orden alfabético. Además, TRUE es 1 y FALSE es 0. Por lo tanto, FALSE < TRUE es TRUE.

- ¿Cuál es el resultado de cada escenario?

- -6 * 5 + 2 es mayor que o igual que -10 + 1.
- "raining" es menor que o igual a "raining dogs".
- TRUE es mayor que FALSE.
- Con operadores relacionales, encontrar la respuesta lógica, i.e. TRUE or FALSE
- En qué días las visitas a los perfiles de LinkedIn excedieron 15?

- ¿Cuándo se vio 5 veces o menos?
- ¿Cuándo se veía más LinkedIn que Facebook?

(Ver figura 1.40)

```
# 1
# Comparacion de numeros
-6*5+2 >= -10 + 1

# Comparación de caracteres
"Ingeniero" <= "Ingeniero Industrial"

# Comparacion de valores logicos
TRUE > FALSE

# 2
# Se han creado los vectores de LinkedIn y Facebook
linkedin <- c(16, 9, 13, 5, 2, 17, 14)
facebook <- c(17, 7, 5, 16, 8, 13, 14)

# Días populares
linkedin > 15

# Días no populares
linkedin <= 5

# LinkedIn más popular que Facebook
linkedin > facebook
```

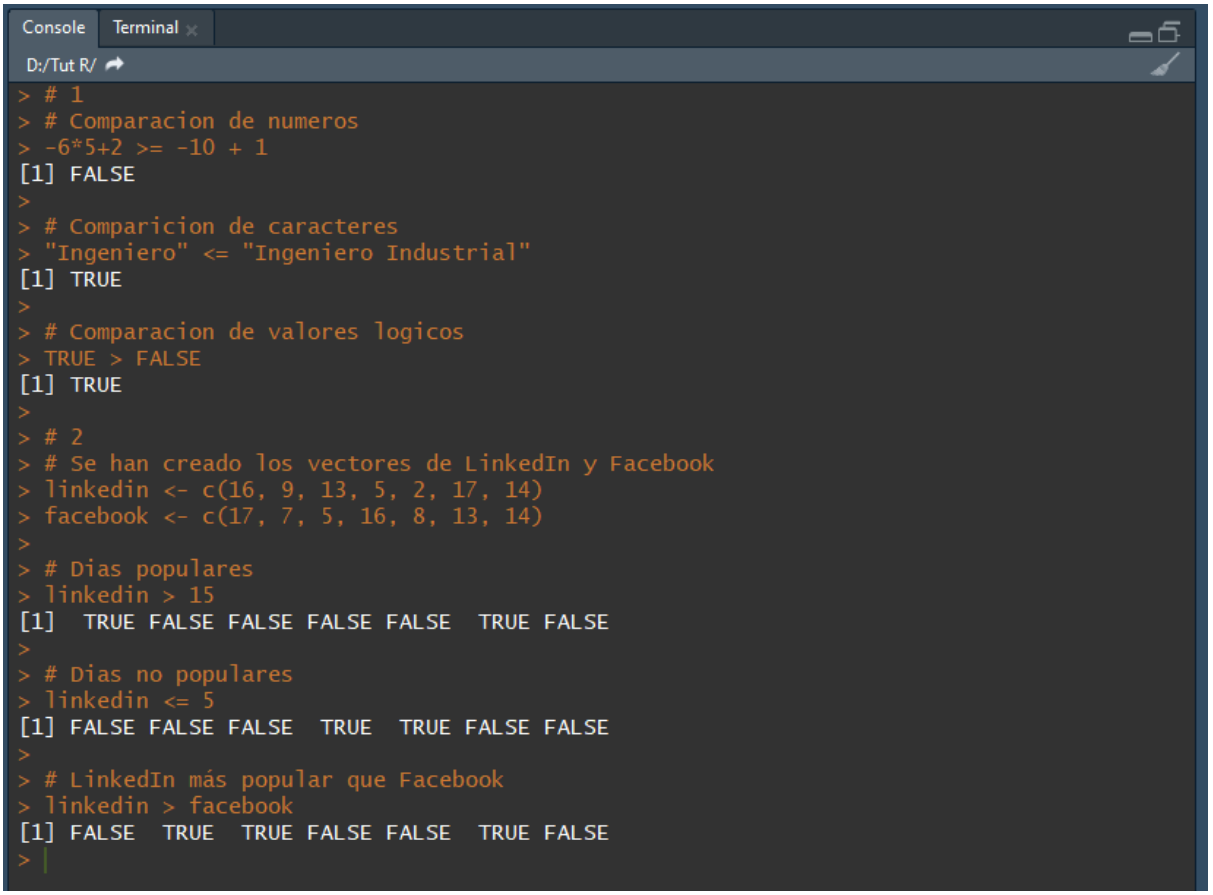

(Figura 1.40) Es posible conocer en qué momentos de la semana se usa más una red social que otra.

1.17 Operadores Lógicos

Son usados para cambiar o combinar resultados de los operadores relacionales.

- AND operator &
  - Compara 2 valores lógicos y regresa TRUE si ambos valores lógicos son TRUE.

- OR operator |
  - Compara 2 valores lógicos y regresa TRUE si al menos uno de los valores lógicos es TRUE.

- NOT operator !
  - Valor negativo del valor lógico que antecede..

& and |
Observar cómo los operadores lógicos funcionan con las relaciones lógicas: (Ver figura 1.41)

```
TRUE & TRUE
```

```
FALSE | TRUE
5 <= 5 & 2 < 3
3 < 4 | 7 < 6
```

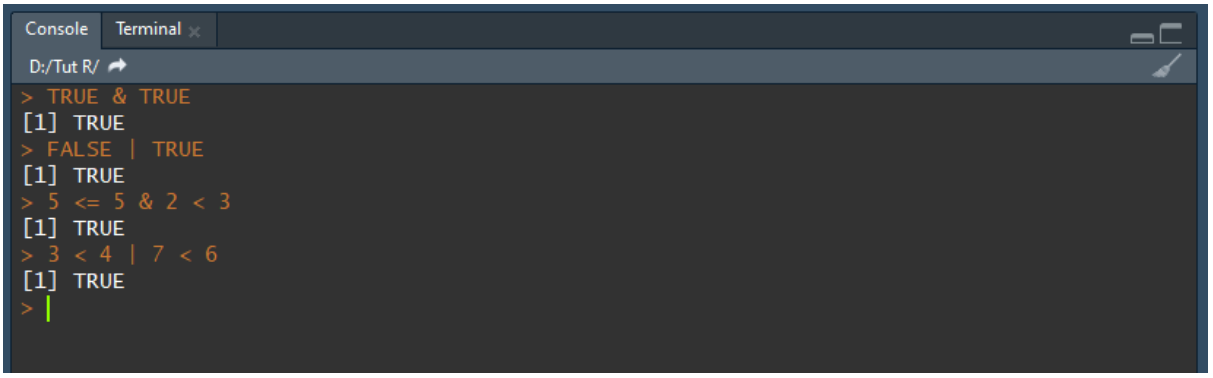

(Figura 1.41) Con estos operadores lógicos es posible comparar objetos.

Importante: 3 < x < 7
No funcionará, sin embargo 3 < x & x < 7 sí.

- Resolver lo siguiente con la variable last:
- last es menor a 5 o mayor a 10?
- last está entre 15 y 20, excluyendo 15 pero incluyendo 20? (Ver figura 1.42)

```
# 1
linkedin <- c(16, 9, 13, 5, 2, 17, 14)

# tail(vector, number of values)
last <- tail(linkedin, 1)
last

# Is last under 5 or above 10?
last < 5 | last > 10

# Is last between 15 (exclusive) and 20 (inclusive)?
last > 15 & last <= 20
```

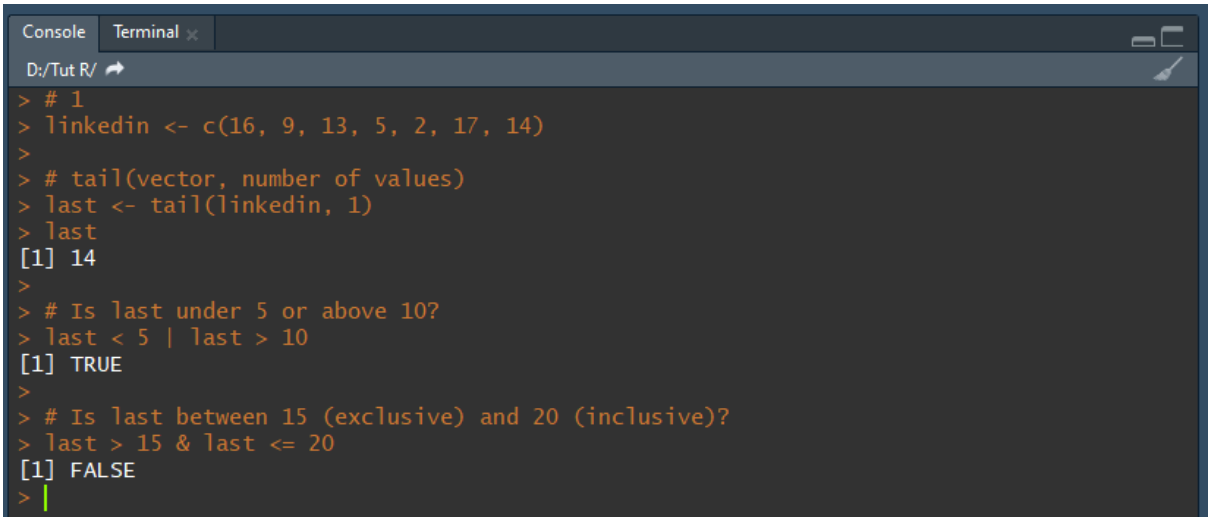

(Figura 1.42) Es posible hacer simples enunciados algebraicos.

1.18 El enunciado if

(Ver figura 1.43)

Sintaxis:

```
if (condition) {
                  expr
                }
```

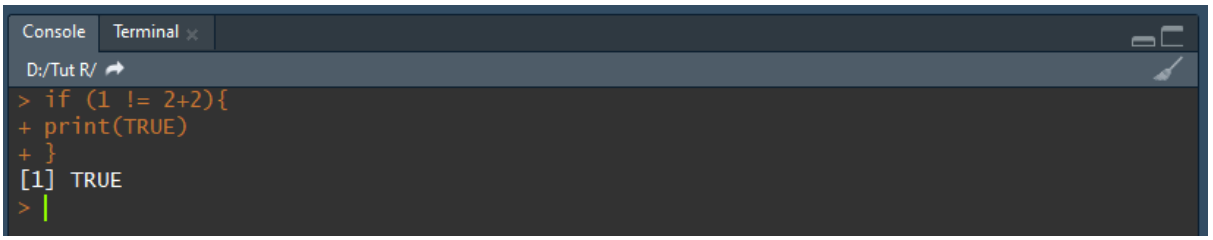

(Figura 1.43) Ejemplo de sintaxis del enunciado.

- Escribir una condición if que imprima "Mostrando información de LinkedIn" si la variable medio es "LinkedIn".
- Escribir una condición if que diga "eres popular!" si la variable num_views es mayor a 15.

(Ver figura 1.44)

```
# Variables
medium <- "LinkedIn"
num_views <- 14

# Examinar la condición if para medium
if (medium == "LinkedIn") {
  print("Mostrando información de  LinkedIn ")
}
```

```
# Write the if statement for num_views
if (num_views > 15) {
  print("eres popular!")
}
```

(Figura 1.44) Se observa que en el segundo enunciado la consola no imprime nada dado que el resultado de la evaluación es FALSE.

Agregar else

Solo puede usarse la expresión else en combinación con una expresión if. La expresión else no requiere una condición, el código que contiene la expresión es ejecutado si todas las expresiones if anteriores son FALSE.(Ver figura 1.45)

```
if (condition) {
      expr1
} else {
      expr2
}
```

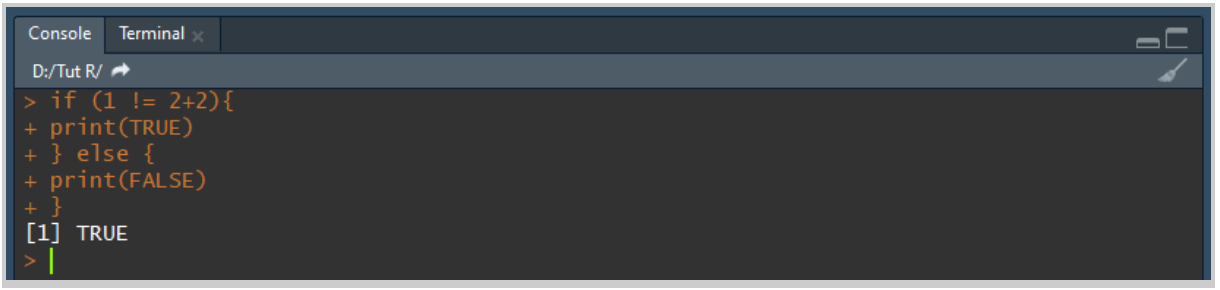

(Figura 1.45) Es importante que *else* esté en el mismo renglón que el corchete de cierre de la expresión if.

Agregar una expresión else a las expresiones anteriores de modo qué:
- Se imprima "Medio Desconocido" cuando no sea "LinkedIn".
- Imprimir "No eres popular " cuando no se cumpla la condición num_views.
(Ver figura 1.46)

```
# Variables related to your last day of recordings
medium <- "LinkedIn"
num_views <- 14

# Estructura de Control para medium
if (medium == "LinkedIn") {
  print("Mostrando información de  LinkedIn")
} else{
  print("Medio Desconocido")
}

# Estructura de Control para medium
if (num_views > 15) {
  print("eres popular!")
  } else{
  print("No eres popular ")
  }
```

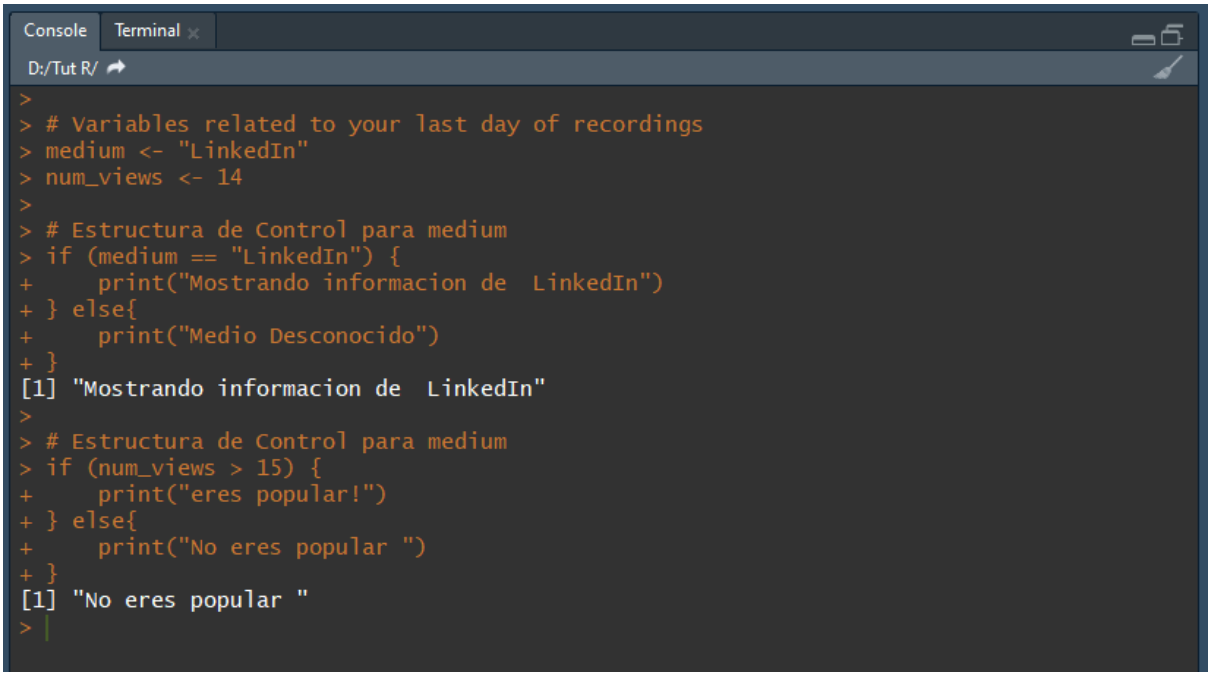

(Figura 1.46) El corchete de else se ejecuta solo si la expresión es evaluada como FALSE

1.19 else if

La expresión else if permite mayor estructura y control. Se pueden agregar tantos sean necesarios, hay que considerar que una vez que una expresión regrese TRUE y se ejecuten

sus expresiones, ya no se seguirán evaluando el resto de las expresiones siguientes. (Ver figura 1.47)

```
#if (condition1) {
#  expr1
#} else if (condition2) {
#  expr2
#} else if (condition3) {
#  expr3
#} else {
#  expr4
#}
```

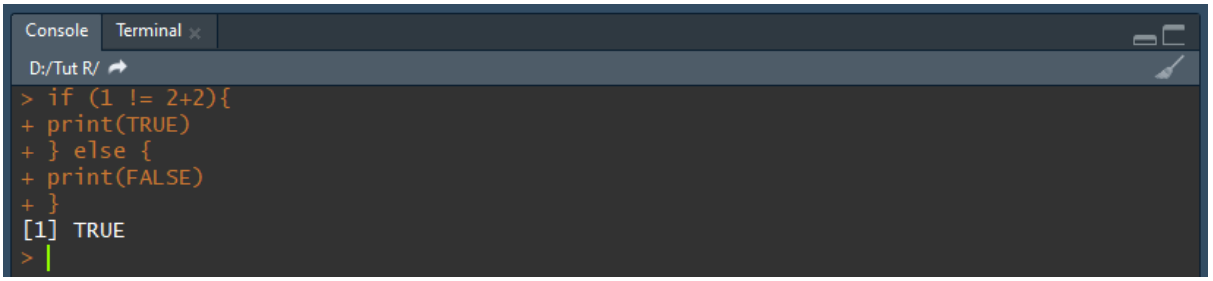

(Figura 1.47) Simple enunciado else if.

Al igual que else, es importante que la expresión else if esté en la misma línea que el corchete de cierre.

Agregar una expresión else a las expresiones anteriores de modo qué:

- Imprimir "Mostrando Información de Facebook" si medium es igual a "Facebook". Recuerda que R distingue Mayúsculas!
- Imprimir "Numero de vistas es promedio" si num_views está entre 15 (inclusivo) y 10 (exclusivo). (Ver figura 1.48)

```
# Variables related to your last day of recordings
medium <- "LinkedIn"
num_views <- 14

# Estructura de control para medium
if (medium == "LinkedIn") {
  print("Mostrando información de  LinkedIn")
} else if (medium == "Facebook") {
  # agregar código para true
  print("Mostrando información de Facebook ")
} else {
  print("Medio Desconocido")
}
```

```
# Estructura de control para num_views
if (num_views > 15) {
  print("eres popular!")
} else if (num_views <= 15 & num_views > 10) {
  # Add code to print correct string when condition is TRUE
  print("numero de vistas promedio")
} else {
  print("No eres popular")
}
```

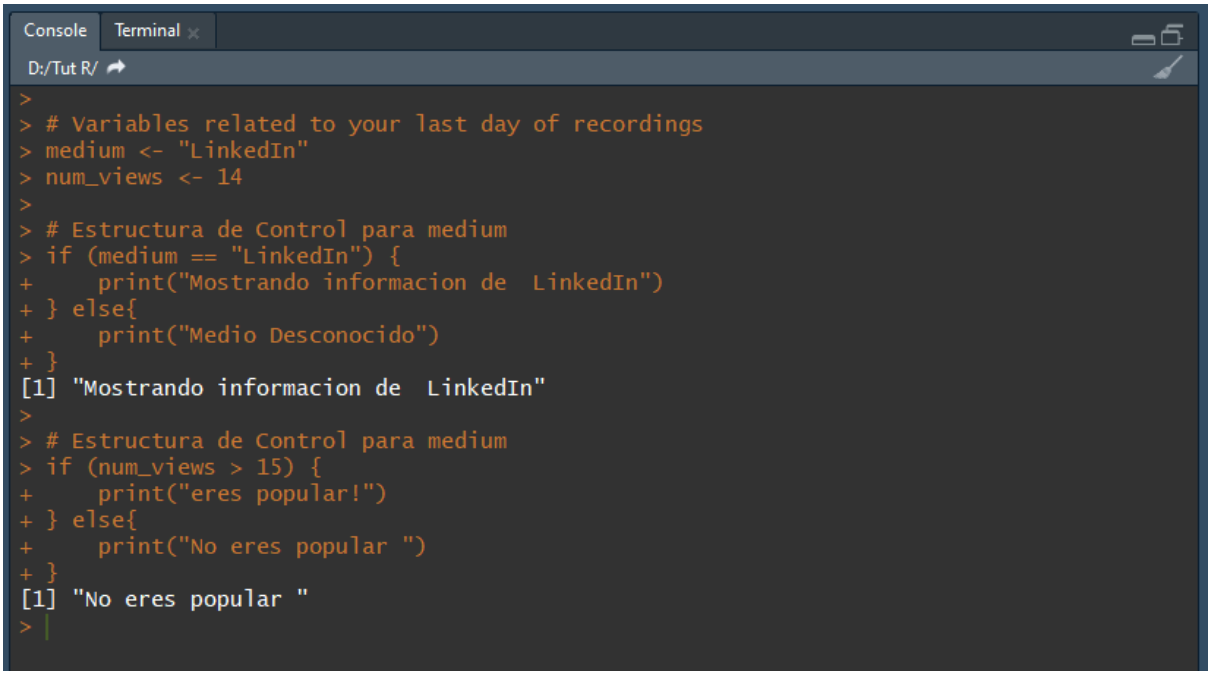

(Figura 1.48) Cuando se incluye el enunciado else, este se ejecuta cuando la evaluación es negativa.

1.20 Vectores (continuación)

Selección por comparaciones. Con los operadores podemos responder diferentes preguntas de manera más ágil.

Repasando, los operadores que hay son:

*'<' menor qué
*'>' mayor qué
*'<=' menor o igual
*'>=' mayor o igual
*'==' igualdad
*'!=' diferencia

Como se vio en el capítulo anterior, declarar 6> 5 devuelve VERDADERO. Lo bueno de R es que puede usar estos operadores de comparación también en vectores. Por ejemplo:(Ver figura 1.49)

```
c(4, 5, 6) > 5
```

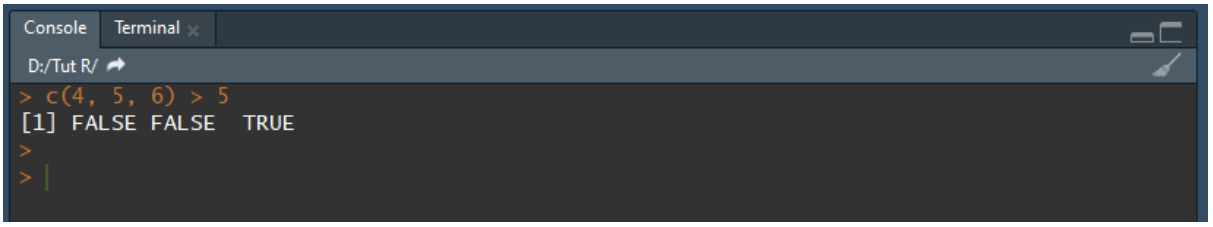

(Figura 1.49) El comando probó el operador en cada uno de los elementos.

Comprobar qué elementos en poker_vector son positivos (es decir,> 0) y asígnele a selection_vector.
Imprimir selection_vector para que pueda inspeccionarse.

La impresión le indica si ganó (VERDADERO) o perdió (FALSO) dinero por cada día. (Ver figura 1.50)

```
# Ganancias de póker y ruleta de lunes a viernes:
poker_vector
roulette_vector

# Que dias hubo ganancia en poker
selection_vector <- poker_vector > 0

selection_vector
```

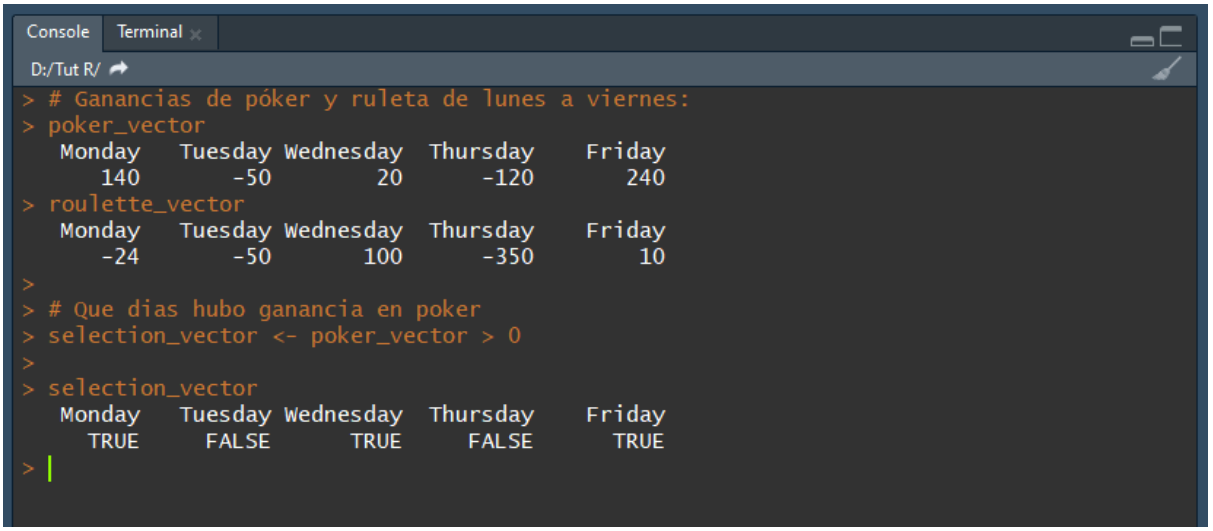

(Figura 1.50) Al asignar el resultado de una operación a un objeto e imprimirlo, tenemos un resultado más claro por cada día de la semana.

Comparación de selección (solo vectores verdaderos)

Trabajar con comparaciones facilitará su vida analítica de datos. En lugar de seleccionar un subconjunto de días para investigarse (como antes), simplemente puede pedirle a R que regrese solo aquellos días en los que se dio cuenta de un retorno positivo para el póker.

En los ejercicios anteriores usó:
selection_vector <- poker_vector> 0 para encontrar los días en los que tuvo un retorno de póker positivo. Ahora, le gustaría saber no solo los días en que ganó, sino también cuánto ganó en esos días.

Puede seleccionar los elementos deseados, colocando selection_vector entre los corchetes que siguen a poker_vector:

```
poker_vector [selection_vector]
```

R sabe qué hacer cuando pasa un vector lógico entre corchetes: solo seleccionará los elementos que corresponden a VERDADERO en selection_vector.

Instrucciones: Use selection_vector entre corchetes para asignar las cantidades que ganó en los días rentables a la variable poker_winning_days.(Ver figura 1.52)

```
# Ganancias de póker y ruleta de lunes a viernes:
poker_vector
roulette_vector

# Que dias hubo ganancia con poker?
selection_vector <- poker_vector > 0

# Seleccionar dias con ganancia
poker_winning_days <- poker_vector[selection_vector]
```

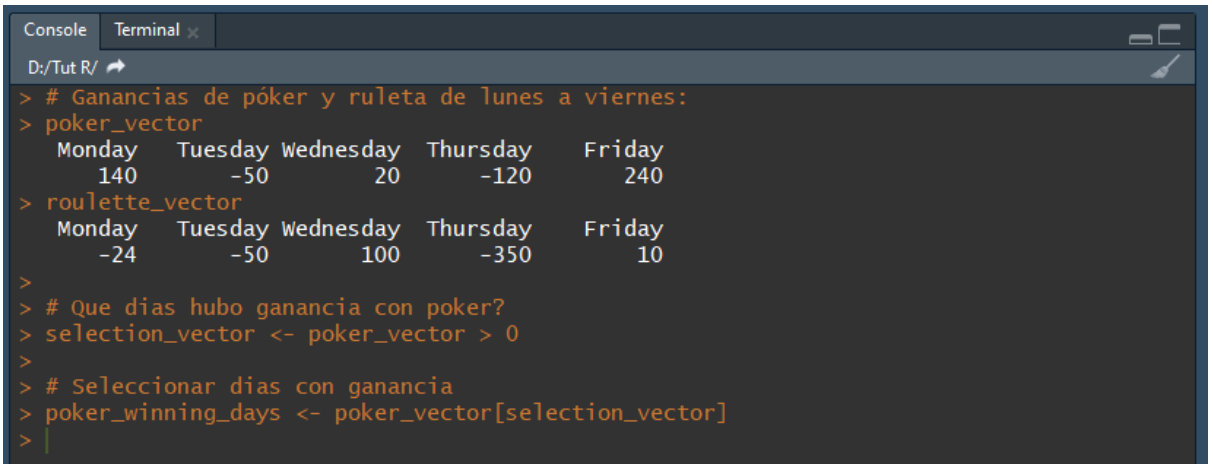

(Figura 1.52) Los días con ganancia en Poker son asignados a la última variable.

1.21 Selección avanzada

Al igual que lo hizo para el póker, también desea saber aquellos días en los que se dio cuenta de un retorno positivo para la ruleta.

Crear la variable selection_vector, esta vez para ver si obtuvo ganancias con la ruleta durante diferentes días.
Asignar las cantidades que realizó en los días en que finalizó positivamente para la ruleta a la variable roulette_winning_days. Este vector contiene las ganancias positivas de roulette_vector.(Ver figura 1.53)

```
# Ganancias de póker y ruleta de lunes a viernes:
poker_vector
roulette_vector

# Que dias hubo ganancia en la ruleta?
selection_vector <- roulette_vector > 0

# Seleccionar dias ganados
roulette_winning_days <- roulette_vector[selection_vector]

#Imprimir resultado
roulette_winning_days
```

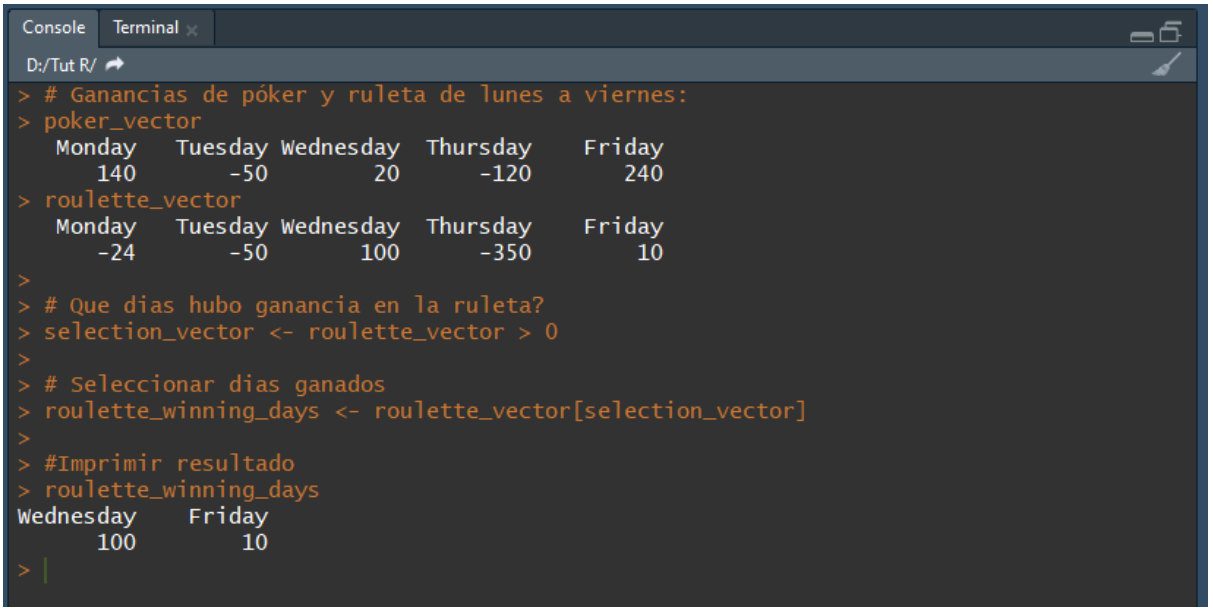

(Figura 1.53) Los únicos días que la ruleta tiene ganancia son miércoles y viernes.

1.22 Matrices

Son las de álgebra.

En R, una matriz es una colección de elementos del mismo tipo (numeric, character, or logical) en un arreglo matricial con un número fijo de filas y columnas. Al trabajar con filas y columnas, se considera que la matriz es de 2 dimensiones.

matrix(1:9, byrow = TRUE, nrow = 3)

En la función matrix():

El primer argumento son los elementos que R acomodará matricialmente, Notar que 1:9 es una versión abreviada para un conjunto de números del 1 al 9 c(1, 2, 3, 4, 5, 6, 7, 8, 9).

El argumento byrow indica que el arreglo matricial será por renglón. Si quisiéramos que fuera por columnas, se escribe byrow = FALSE.
El tercer argumento indica cuántos renglones habrá.

Construir una matriz de 3 filas con los números del 1 al 9 en un arreglo por renglón. (Ver figura 1.54)

```
#Construir una matriz de 3 filas con los números del 1 al 9
matrix( 1:9 , byrow=TRUE, nrow=3)
```

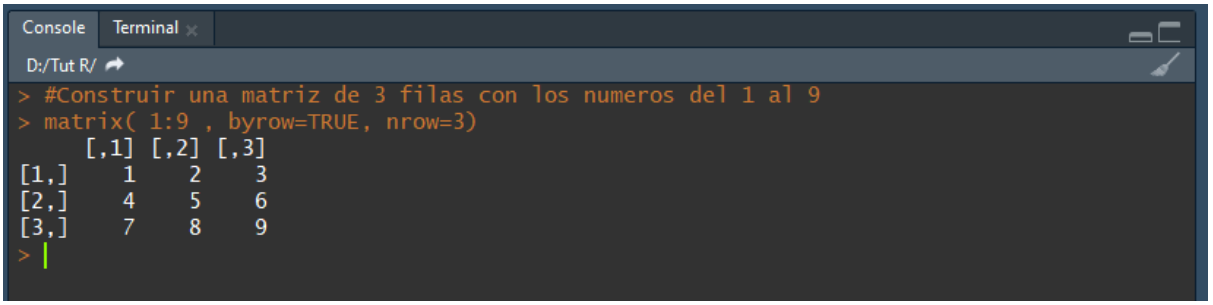

(Figura 1.54) se observa la matriz generada.

1.23 Nombrar una matriz

Para recordar lo que está almacenado en alguna matriz, es deseable agregar los nombres para las filas o columnas. Esto no solo ayuda a leer los datos, sino que también es útil para seleccionar ciertos elementos de la matriz.

rownames (var_matrix) <- row_names_vector
colnames (var_matrix) <- col_names_vector

Seguimos adelante y preparamos dos vectores para usted: región y títulos. Necesitará estos vectores para nombrar las columnas y filas de star_wars_matrix, respectivamente.

Usar colnames() para nombrar las columnas de star_wars_matrix con el vector de la region.
Usar rownames() para nombrar los renglones de star_wars_matrix con el vector de titulos.

Imprimir la matriz star_wars_matrix para ver el resultado. (Ver figura 1.55)

```
# Box office Star Wars
new_hope <- c(460.998, 314.4)
empire_strikes <- c(290.475, 247.900)
return_jedi <- c(309.306, 165.8)

# Construir matrix
star_wars_matrix <- matrix(c(new_hope, empire_strikes,
return_jedi), nrow = 3, byrow = TRUE)

# Vectores region y titles, usados para nombramiento
region <- c("US", "non-US")
titles <- c("A New Hope", "The Empire Strikes Back", "Return
of the Jedi")

# Nombrar columnas con region
colnames(star_wars_matrix) <- region

# Nombrar renglones con titulos
rownames(star_wars_matrix) <- titles

# Imprimir
star_wars_matrix
```

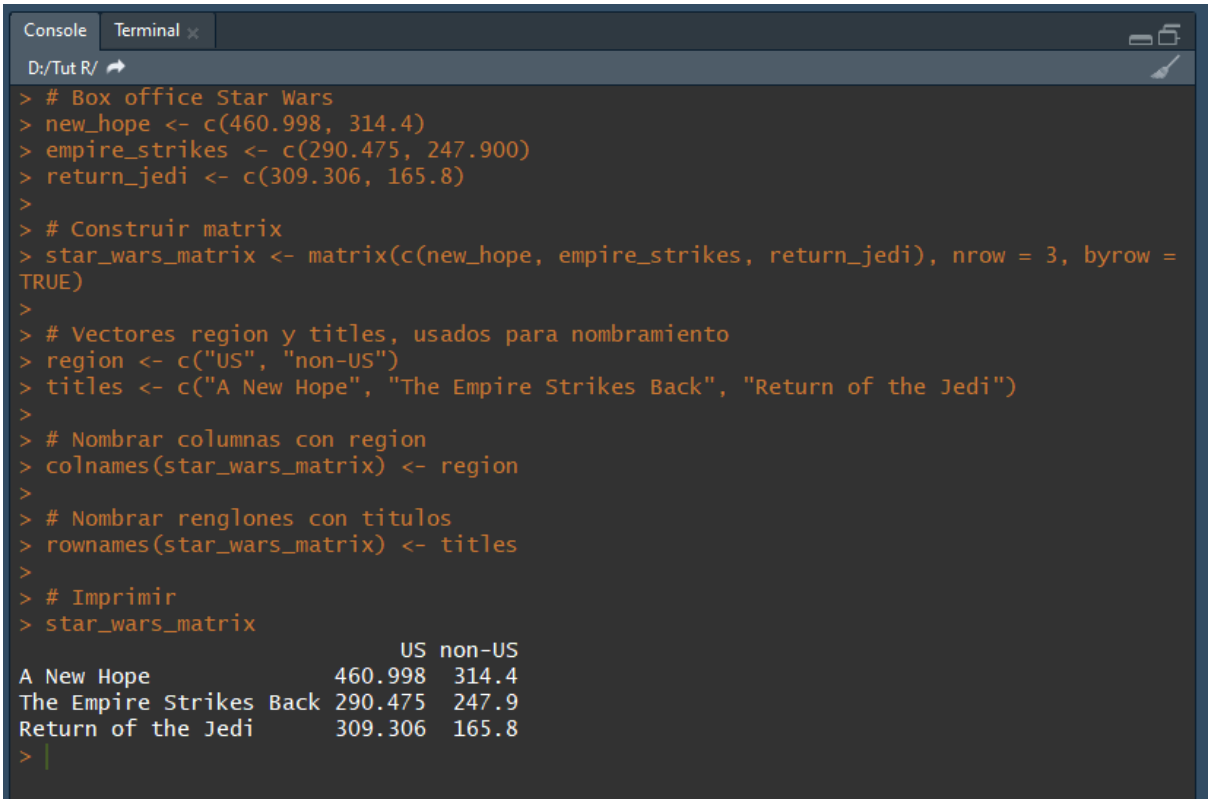

(Figura 1.55) El objeto Star_wars_matrix almacena la matriz y los nombres de renglones y columnas.

1.24 Cálculos por renglón

In R, la función rowSums() convenientemente calcula la suma de todos los renglones, esto crea un vector:(Ver figura 1.56)

rowSums(my_matrix)

Instrucciones, calcular la taquilla mundial

```
# Construir matriz
box_office <- c(460.998, 314.4, 290.475, 247.900, 309.306, 165.8)
star_wars_matrix <- matrix(box_office, nrow = 3, byrow = TRUE,
                           dimnames = list(c("A New Hope", "The Empire Strikes Back", "Return of the Jedi"), c("US", "non-US")))

# Calcular taquilla mundial
worldwide_vector <- rowSums(star_wars_matrix)

worldwide_vector
```

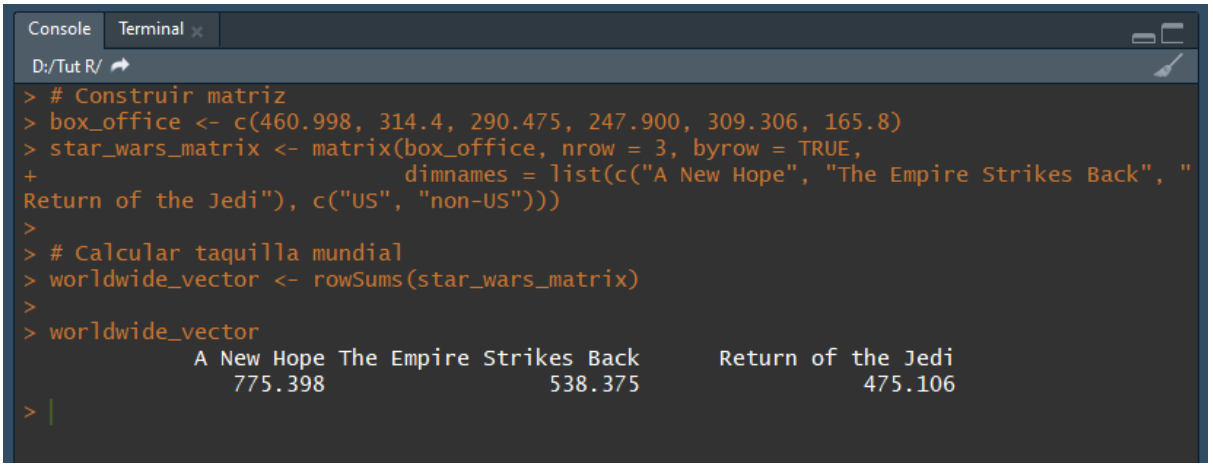

(Figura 1.56) Resultado de la taquilla de cada película.

1.25 Agregar una columna a una matriz

Puede agregar una columna o varias columnas a una matriz con la función cbind (), que combina matrices y / o vectores por columna. Por ejemplo:

big_matrix <- cbind(matrix1, matrix2, vector1 ...)

Agregar worldwide_vector como una nueva columna a la matriz star_wars_matrix y asignar a todo_starwars_matrix. Usar la funcion cbind()(Ver figura 1.57)

```
#  star_wars_matrix
box_office <- c(460.998, 314.4, 290.475, 247.900, 309.306,
165.8)
star_wars_matrix <- matrix(box_office, nrow = 3, byrow = TRUE,
                           dimnames = list(c("A New Hope",
"The Empire Strikes Back", "Return of the Jedi"),
                                           c("US", "non-US")))
# taquilla mundial
worldwide_vector <- rowSums(star_wars_matrix)

#agregar la nueva variable a la matriz
all_wars_matrix <- cbind(star_wars_matrix,worldwide_vector)

all_wars_matrix
```

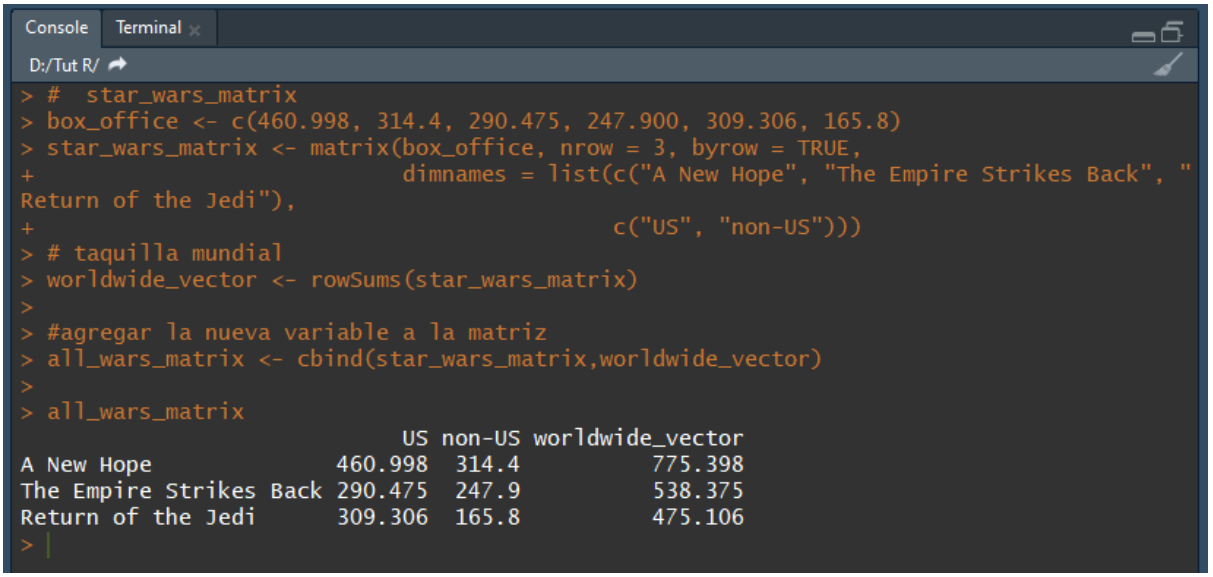

(Figura 1.57) Ahora se incluye la suma en la matriz.

1.26 Agregar una fila a una matriz

Puede agregar una fila o varias filas a una matriz con la función rbind (), que combina matrices y / o vectores juntos por fila. Por ejemplo:

```
big_matrix <- rbind (matriz1, matriz2, vector1 ...)
```

1.27 Suma de columna

Su espacio de trabajo de R ya contiene la matriz all_wars_matrix que construyó en el ejercicio anterior; escriba all_wars_matrix para verla. Ahora se calculan los ingresos totales de taquilla para toda la saga.

Calcule los ingresos totales para los EE. UU. Y la región no estadounidense y asigne total_revenue_vector. Puede usar la función colSums ().
Imprima total_revenue_vector para ver los resultados.
(Ver figura 1.59)

```
all_wars_matrix

# ganancias totales
total_revenue_vector <- colSums(all_wars_matrix)
```

```
total_revenue_vector
```

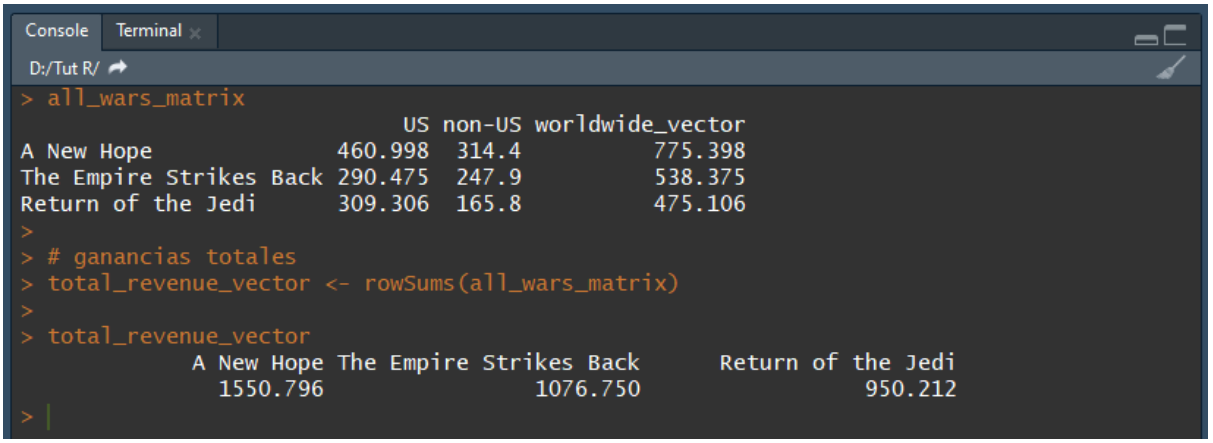

(Figura 1.59)

1.28 Selección de elementos matriciales

Similar a los vectores, puede usar los corchetes [] para seleccionar uno o varios elementos de una matriz. Mientras que los vectores tienen una dimensión, las matrices tienen dos dimensiones. Por lo tanto, debe usar una coma para separar qué seleccionar de las filas de lo que desea seleccionar de las columnas. Por ejemplo:

my_matrix [1,2] selecciona el elemento en la primera fila y la segunda columna. my_matrix [1: 3,2: 4] da como resultado una matriz con los datos en las filas 1, 2, 3 y las columnas 2, 3, 4. Si desea seleccionar todos los elementos de una fila o columna, no hay número necesario antes o después de la coma, respectivamente:

my_matrix [, 1] selecciona todos los elementos de la primera columna. my_matrix [1,] selecciona todos los elementos de la primera fila.

Seleccione los ingresos no estadounidenses para todas las películas (la segunda columna completa de all_wars_matrix), almacene el resultado como non_us_all.
Use mean () en non_us_all para calcular el ingreso promedio no estadounidense para todas las películas. Simplemente imprima el resultado.
Esta vez, seleccione los ingresos no estadounidenses para las dos primeras películas en all_wars_matrix. Almacene el resultado como non_us_some.
Use mean () nuevamente para imprimir el promedio de los valores en non_us_some.
(Ver figura 1.60)

```
all_wars_matrix
# Selecciona las non-US r
non_us_all <- all_wars_matrix[,2]
# promedio non-US revenue
mean(non_us_all)
```

```
# Seleccionar non-US revenue de las primeras 2 peliuclas
non_us_some <- all_wars_matrix[1:2,2]
# promedio de las primeras 2 peliuclas
mean(non_us_some)
```

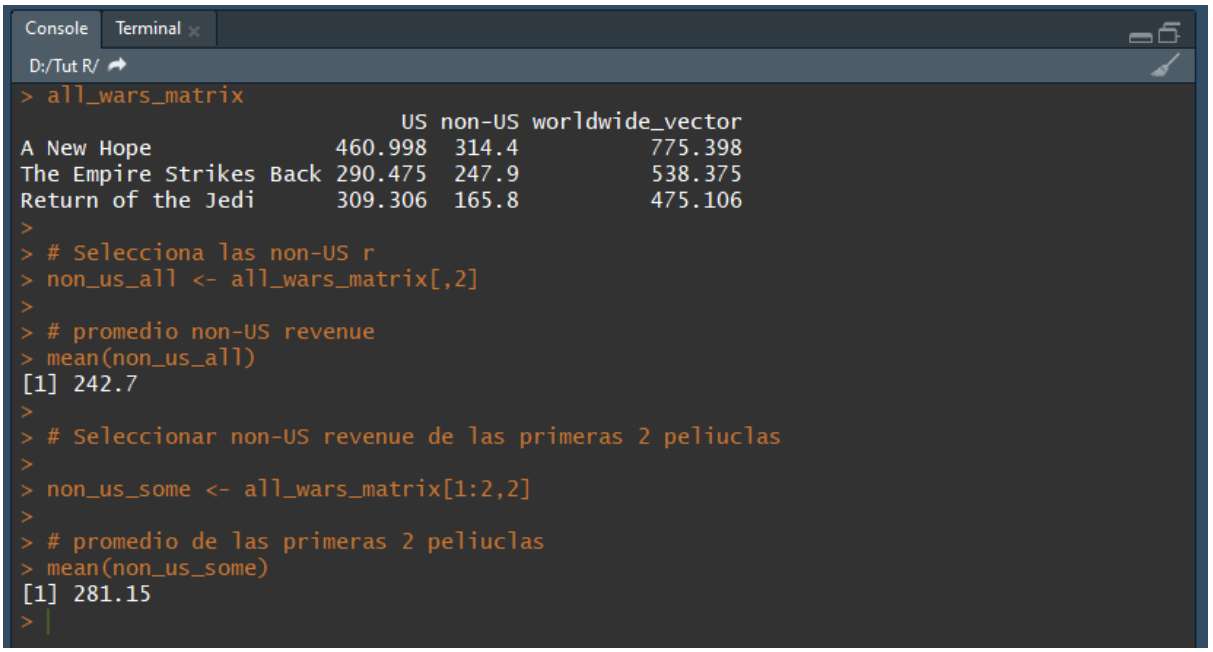

(Ver figura 1.60) Al igual que en álgebra se ejecutan operaciones en la matriz.

1.29 Un poco de aritmética con matrices.

Similar a lo que ha aprendido con los vectores, los operadores estándar como +, -, /, *, etc. funcionan de manera inteligente en matrices en R.

Por ejemplo, 2 * my_matrix multiplica cada elemento de my_matrix por dos.

Al igual que 2 * my_matrix multiplicó cada elemento de my_matrix por dos, my_matrix1 * my_matrix2 crea una matriz donde cada elemento es el producto de los elementos correspondientes en my_matrix1 y my_matrix2.

Después de ver el resultado del ejercicio anterior los precios de las entradas aumentaron con el tiempo. Se realiza el análisis en función de los precios que puede encontrar en ticket_prices_matrix

Aquellos que estén familiarizados con las matrices deben tener en cuenta que esta no es la multiplicación de matrices estándar para la que debe usar %*% en R.

Dividir all_wars_matrix por ticket_prices_matrix para obtener el número estimado de visitantes estadounidenses y no estadounidenses para las seis películas. Asignar el resultado a los visitantes.

En la matriz de visitantes, seleccione la primera columna completa, que representa el número de visitantes en los EE. UU. Almacene esta selección como us_visitors.

Calcule el número promedio de visitantes estadounidenses; imprime el resultado. (Ver figura 1.63)

```
all_wars_matrix
ticket_prices_matrix<- matrix(c(4.5,5,5.5), nrow = 3, byrow = TRUE)
# Estimar admisiones
visitors <- all_wars_matrix[4]/ticket_prices_matrix
# admisiones US
us_visitors <- visitors[1,]
```

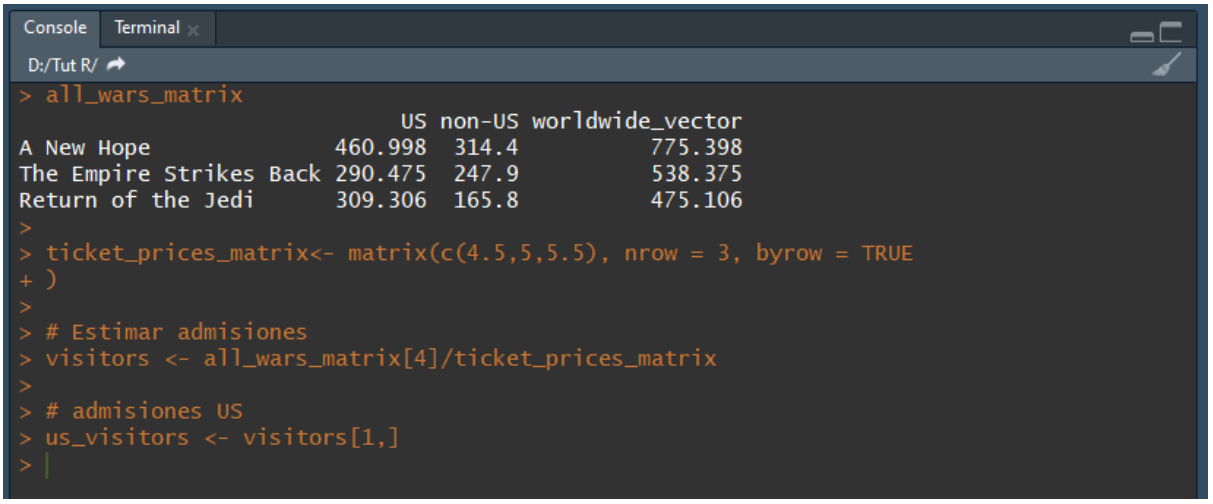

(Figura 1.63) El valor de las admisiones estimadas está en el objeto us_visitors.

1.30 Comparación de matrices

R posee una habilidad para trabajar con diferentes estructuras de datos; los operadores relacionales pueden ser usados en matrices.

Ahora, se ha generado una matriz con las mismas vistas a Facebook y LinkedIn, los vectores originales siguen disponibles. (Ver figura 1.64)

- ¿Cuándo ha habido 13 vistas? Usar la matriz vistas.
- ¿En qué días han sido igual o menores a 14?

```
linkedin <- c(16, 9, 13, 5, 2, 17, 14)
facebook <- c(17, 7, 5, 16, 8, 13, 14)
views <- matrix(c(linkedin, facebook), nrow = 2, byrow = TRUE)
# Cuando las vistas son igual 13?
```

```
views == 13
# Cuando son menor o igual a 14?
views <= 14
```

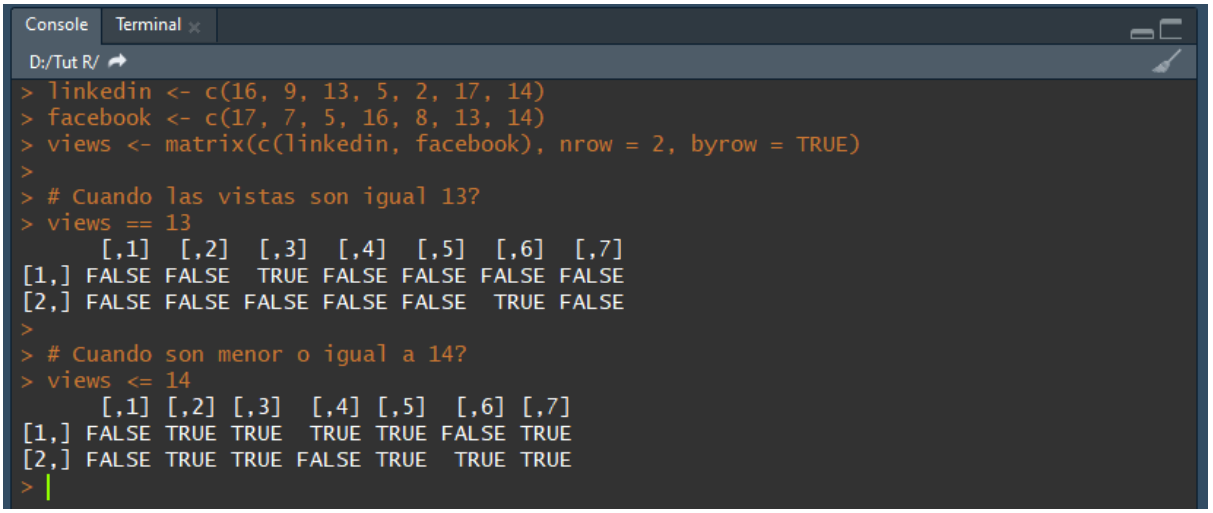

(Figura 1.64) El resultado es una matriz con cada elemento evaluado por separado.

2. Conceptos clave en el análisis de datos y alcance del tutorial

La ciencia de datos es una disciplina que permite convertir datos en bruto en percepciones acertadas y conocimiento a partir de dichos datos. A grosso modo, las herramientas usadas en un proyecto de ciencia de datos conviven de la siguiente manera:

[9]

2.1 Importación de datos

Es la lectura de datos brutos, que puede ser de las siguientes maneras:

- Leer un archivo
- Conectarse a una base datos
- Conectarse a través de una API (Application Programming Interface)
- *Webscrapping* que consiste en un proceso sistemático en el cual se copia información que se muestra en una página web.

Existe información más detallada según el método de conexión respecto a las mejores prácticas.[10]

2.1.1 Leer, conectar, cargar fuentes de datos

Los datos que buscamos analizar pueden estar en diferentes formatos de archivos (.XLS, .TXT, .CSV, JSON) o bien en bases de datos, para los objetivos de este texto se propone un enfoque en archivos de texto csv.
Es muy sencillo cargar los datos en R por la simplicidad y disponibilidad de librerías.

```
# Leer CSV
Data <- read.csv(file="c:/TheDataIWantToReadIn.csv", header=TRUE,
sep=",")
#Leer TXT
Txt <- read.table("c:/TheDataIWantToReadIn.txt", sep="\t",
header=TRUE)
```

El resto de los comandos de la función Read tienen una estructura similar, al colocar el cursor en read.csv y presionar F1 se observa la viñeta de la documentación de R con las especificaciones de cada argumento.

[9] Gráfico de: R for Data Science, Hardley Wickham

[10] Setting up ODBC Drivers

2.2 Limpieza de datos

También conocido como curación de datos, suele ser una de las partes más laboriosas del proceso y fundamental ya que con la limpieza se busca tener los datos brutos almacenados de una forma consistente que haga sentido con la semántica de la fuente de datos, de esta manera tendremos que cada columna es una variable observada y cada columna es una observación.

2.2.1 Eliminar duplicados

De manera sencilla tenemos:

```
> set.seed(150)
> x <- round(rnorm(20, 10, 5))
> x
 [1] 2 10 6 8 9 11 14 12 11 6 10 0 10 7 7 20 11 17 12 -1
> unique(x)
 [1] 2 10 6 8 9 11 14 12 0 7 20 17 -1
```

2.2.2 Outliers y valores faltantes

Ubicar NA's es realizado de la siguiente manera:

```
> y <- c(4,5,6,NA)
> is.na(y)
[1] FALSE FALSE FALSE TRUE
```

y de esta manera se eliminan los vacíos:

```
y[is.na(y)] <- mean(y,na.rm=TRUE)
y
[1] 4 5 6 5
```

2.3 Transformación de datos

El primer paso común una vez que se tiene un dataset ordenado es transformarlo, y va desde hacer operaciones entre las variables como calcular la velocidad a partir de la aceleración y el tiempo, o bien filtrar alguna variable como podrían ser las personas de una ciudad o los datos en un periodo de tiempo

2.3.1 Tipos de Variables

Los tipos de variable funcionan como su nombre lo indica, cada uno le da diferentes atributos a un objeto, ya sea un nùmero, cadena de texto, matriz o dataframe.

Usando **is.xyz** para probar si es del tipo ***xyz***. Regresa TRUE o FALSE
Usando **as.xyz** para hacer una conversión explícita.

```
is.numeric(), is.character(), is.vector(), is.matrix(), is.data.frame()
 as.numeric(), as.character(), as.vector(), as.matrix(), as.data.frame()
```

Sin embargo, convertir una estructura de datos es más crítico que transformar el formato:

	to one long vector	to matrix	to data frame
from vector	c(x,y)	cbind(x,y) rbind(x,y)	data.frame(x,y)
from matrix	as.vector(mymatrix)		as.data.frame(mymatrix)
from data frame		as.matrix(myframe)	

2.3.2 Transponer sets de datos

Cuando los datos son presentados de manera matricial, podemos hacer operaciones matriciales como la transposición:

id	Class	x1	x2
1	1	5	6
1	2	3	5
2	1	6	1
2	2	2	4

id	Class	variable	value
1	1	x1	5
1	2	x1	3
2	1	x1	6
2	2	x1	2
1	1	x2	6
1	2	x2	5
2	1	x2	1
2	2	x2	4

[11]

```
# Funciòn melt
 library(reshape)
 mdata <- melt(mydata, id=c("id","time"))
```

[11] An Introduction to reshape2 - Reshaping data easily with the reshape2 R package. - seananderson.ca

2.3.3 Ordenar un set de datos

Con la función order(nombre de la variable) se pueden reacomodar las observaciones en un set de datos.

```
# ordenar por var1
newdata <- old[order(var1),]
# ordenar por var1 y var2 (descendiente)
newdata2 <- old[order(var1, -var2),]
```

2.3.4 Muestras de un conjunto de datos en R

Muestrar datos es común al momento de construir un modelo y probarlo. Para tomar una muestra de una fuente de datos se escribe lo siguiente:

```
mysample <- mydata[sample(1:nrow(mydata), 100,replace=FALSE),]
```

Este código contiene 100 observaciones aleatorias de 100 observaciones en la tabla mydata.

2.3.5 Combinar fuentes de datos

Otra operación bastante común:

```
# combinar 2 sets de datos por ID y por país:
total <- merge(data frameA,data frameB,by="ID")
# total <- merge(data frameA,data frameB,by=c("ID","Country")
```

2.4 Visualización de datos

Visualizar es una actividad fundamental de los humanos, una buena visualización podrá mostrar patrones, outliers, y ayudará a saber si se está haciendo la pregunta correcta con los datos disponibles.

2.4.1 Crear histogramas

La sintaxis para la visualización de datos es muy sencilla y genera gráficos claros, a continuación se generará una distribución de puntos y se graficará su variación.

```
puntos <-rnorm(n=1000, m=80, sd=20)
hist(puntos)
```

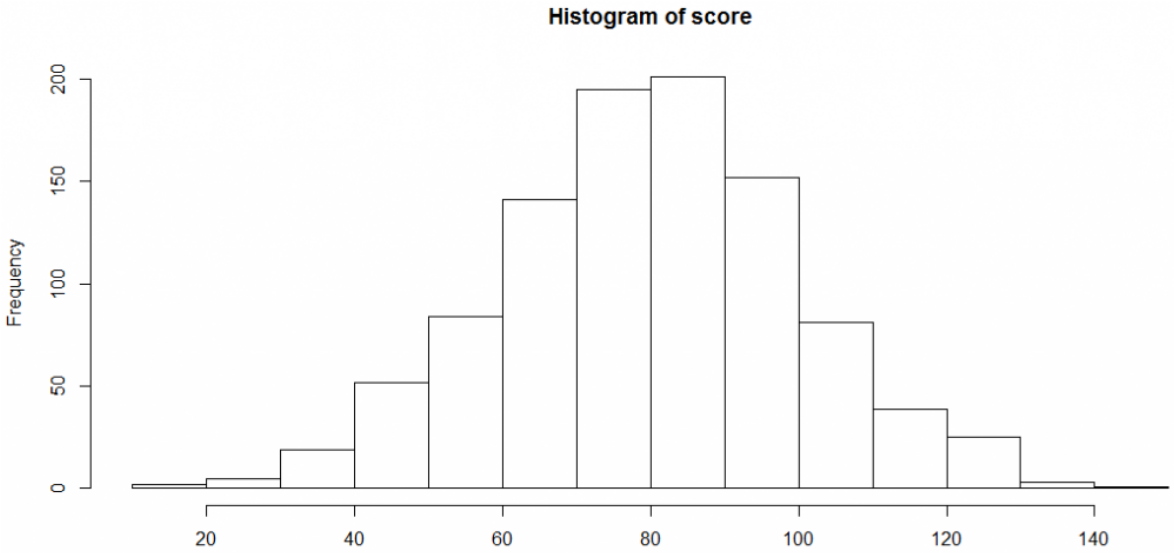

Para conocer los atributos y características que R toma al general los datos escribimos lo siguiente:

```
histinfo<-hist(puntos)
histinfo
$breaks
 [1] 10 20 30 40 50 60 70 80 90 100 110 120 130 140 150
$counts
 [1] 2 5 19 52 84 141 195 201 152 81 39 25 3 1
$density
 [1] 0.0002 0.0005 0.0019 0.0052 0.0084 0.0141 0.0195 0.0201 0.0152
[10] 0.0081 0.0039 0.0025 0.0003 0.0001
$mids
 [1] 15 25 35 45 55 65 75 85 95 105 115 125 135 145
$xname
[1] "puntos"
$equidist
[1] TRUE
attr(,"class")
[1] "histogram"
```

Como se puede observar, breaks indica en que puntos se hacen cortes, se pueden restringir los puntos de corte o variar la densidad. También se puede colorear la gráfica de barras y colocar encima una curva de distribución.

```
hist(puntos, freq=FALSE, xlab="Puntos", main="Distribucion de
puntos", col="lightgreen", xlim=c(0,150), ylim=c(0, 0.02))
curve(dnorm(x, mean=mean(score), sd=sd(score)), add=TRUE,
col="darkblue", lwd=2)
```

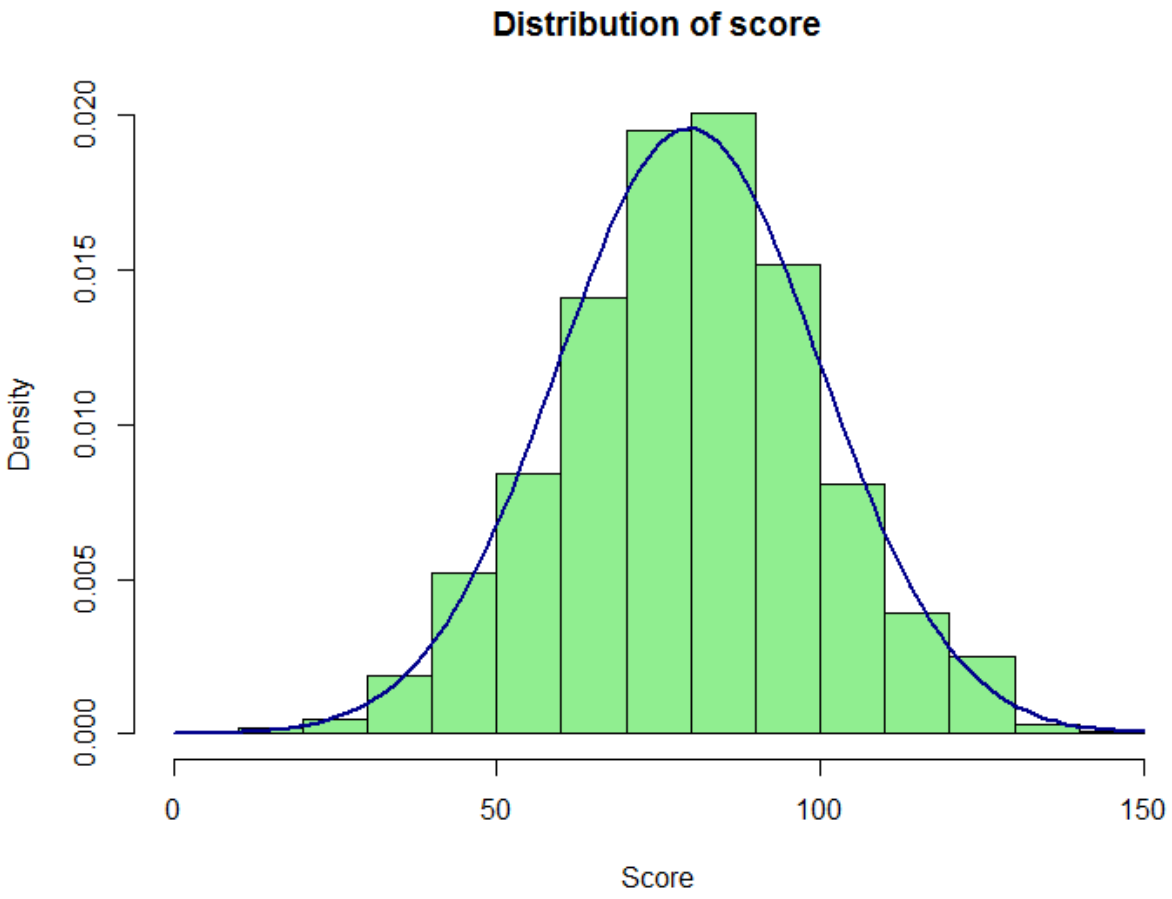

2.5 Modelado

Una forma de validar las preguntas de una forma precisa, se puede usar un modelo que explique los patrones de los datos con los que se cuenta y generar proyecciones y formular hipótesis.

2.5.1 Suma, cuenta y promedio de una variable en un set de datos

Las funciones Apply son útiles para estos cálculos:

```
> tapply(iris$Sepal.Length,iris$Species,sum)
 setosa versicolor virginica
 250.3 296.8 329.4
> tapply(iris$Sepal.Length,iris$Species,mean)
 setosa versicolor virginica
 5.006 5.936 6.588
```

2.6 Exploración y Transformación de Datos

La exploración, transformación y comunicación de datos son tareas fundamentales en proyectos de inteligencia de negocios. La exploración consiste en identificar patrones y tendencias en los datos, mientras que la transformación implica la limpieza y procesamiento de los datos para poder analizarlos adecuadamente. Y la comunicación consiste en transmitir las ideas generadas por los dos pasos anteriores a los miembros clave de la organización o equipo de trabajo.

En esta sección, se explicarán las técnicas y herramientas utilizadas para realizar estas tareas de manera efectiva, para abordar este tema he preparado los siguientes casos de estudio que ilustran este proceso de una manera prácticas con problemas reales.

Como lo he venido planteando desde la introducción, R es un lenguaje de programación muy utilizado en proyectos de inteligencia de negocios debido a su capacidad para importar y manipular datos de diferentes fuentes. Además, R ofrece una variedad de paquetes y librerías que permiten realizar análisis estadísticos y visualización de datos, así como también para la limpieza y preprocesamiento de datos que consiste en herramientas para tratar valores faltantes, valores atípicos y datos duplicados.

3. Caso de Estudio 1: Análisis del flujo de autos en los estacionamientos de la Facultad.

3.1 Objetivo

Analizar los datos para poder tener una matriz de datos limpia que sirva como entrada para un modelo de simulación.

Algunos datos que observar:
Conteo de tarjetas únicas por día
Histograma, identificar periodos intersemestrales y demanda baja

3.2 Importación de datos

Para leer archivos en Excel la librería *readxl()* será usada, al igual que en ejemplos anteriores usaremos *dplyr* de *Tidyverse*.

En la ventana del editor, se escriben las instrucciones para cargar las librerías necesarias para este análisis (Ver figura Caso 1.1):

Se identificará el “Working Directory” para asegurar la lectura del archivo correcto.
Se indicará la ruta correcta con el comando setwd()
Se mostrará los archivos en el directorio de trabajo y se asignan al objeto *plumas2015* la información contenida en el archivo “EVENTOS_2015.xlsx”

```
library('readxl') #leer excel
library('dplyr')  #limpiar archivos

#Asígnanos a un objeto el archivo en Excel:
plumas2015<- read_xlsx(path = 'EVENTOS_2015.xlsx')
```

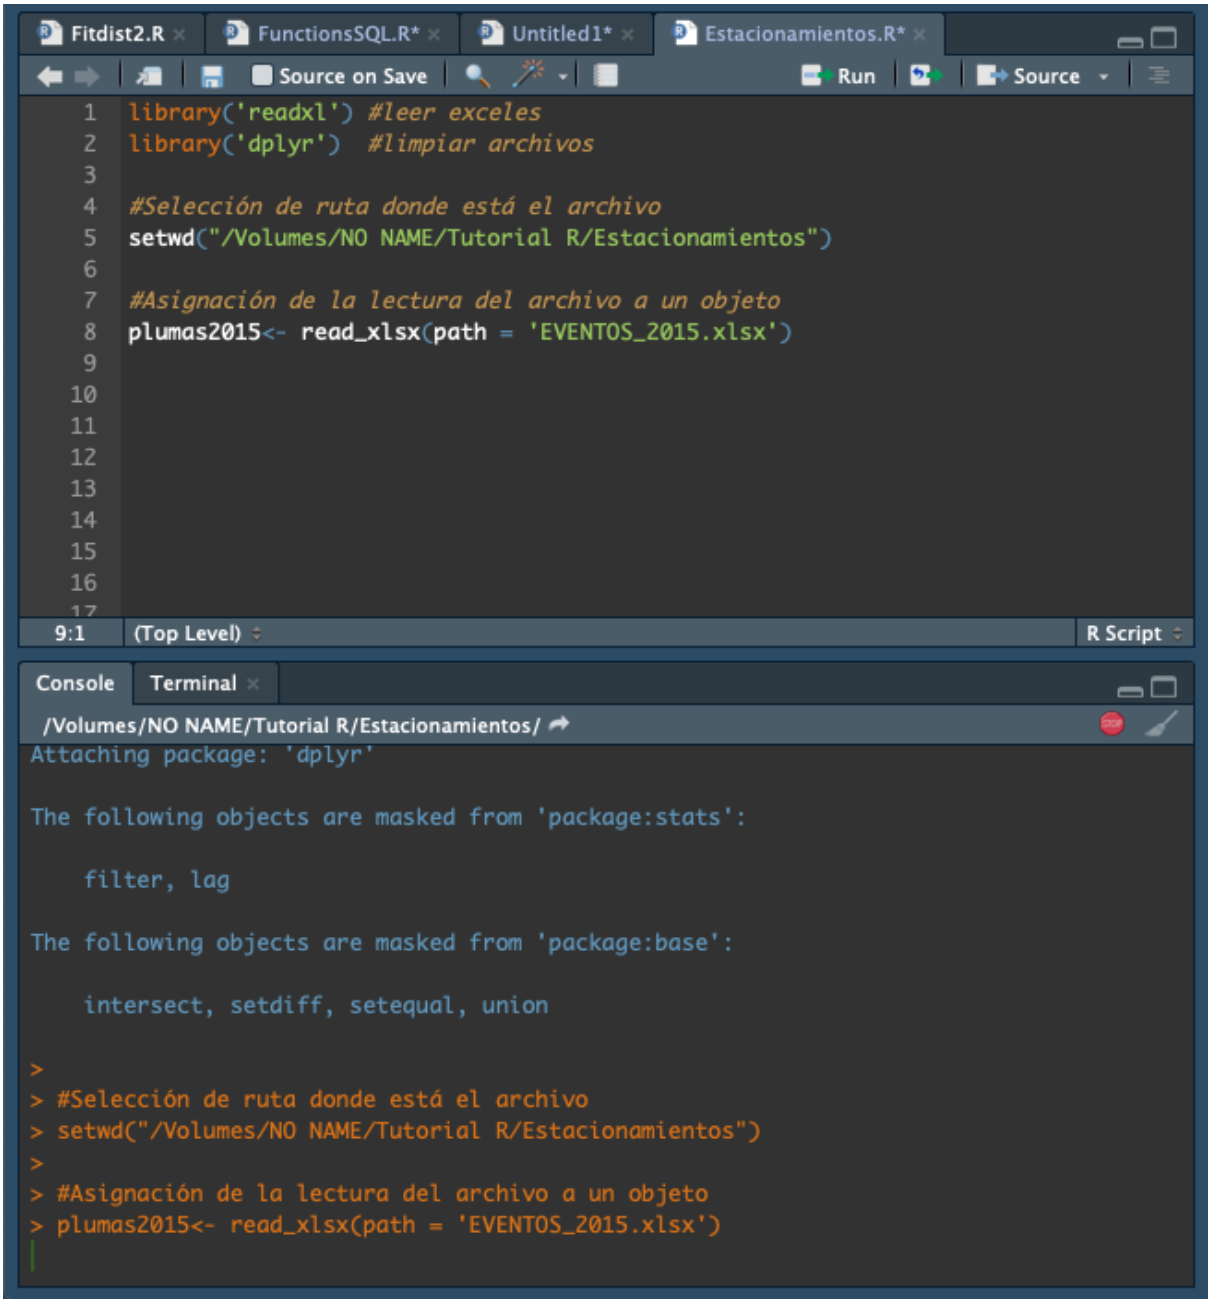

(Figura Caso 1.1) En la parte superior está en script actual y en la inferior las interacciones de la consola.

3.3 Limpieza de datos

Se inicia el análisis exploratorio con las funciones comunes para observar datos (Ver figura Caso 1.2):

```
head(plumas2015,10)
```

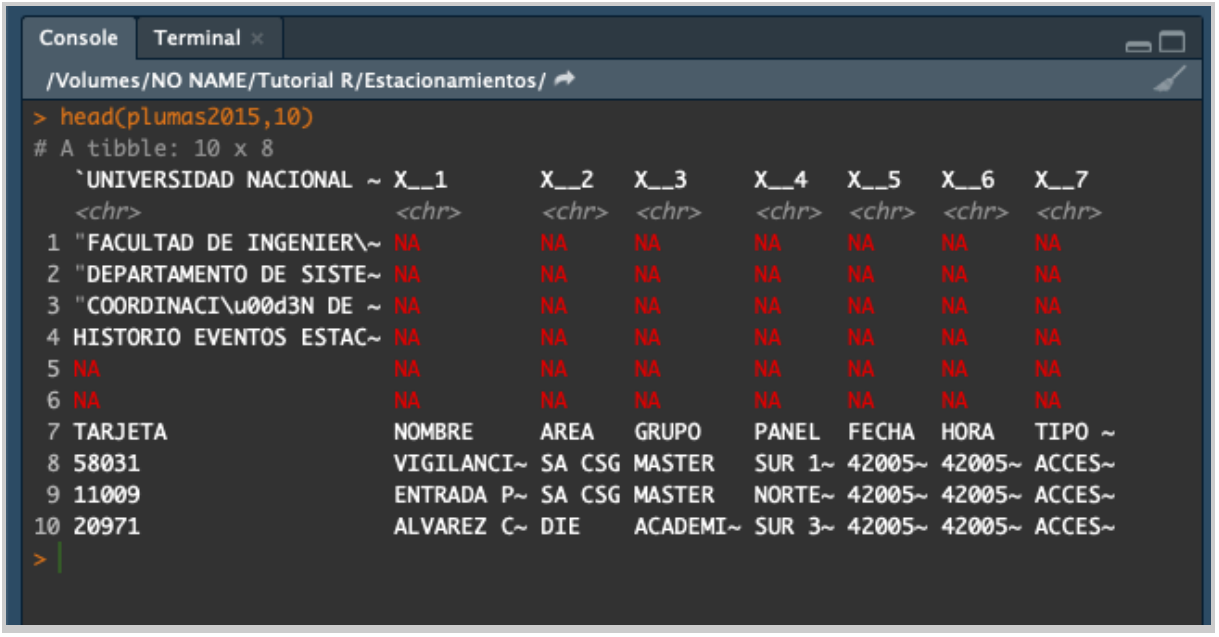

(Figura Caso 1.2) Se aprecian valores vacíos como NA.

Con la notación matricial, se eliminan los renglones no deseados en el set de datos (Ver figura Caso 1.3):

```
plumas2015 <- plumas2015[-c(1:6),-c(2)]
```

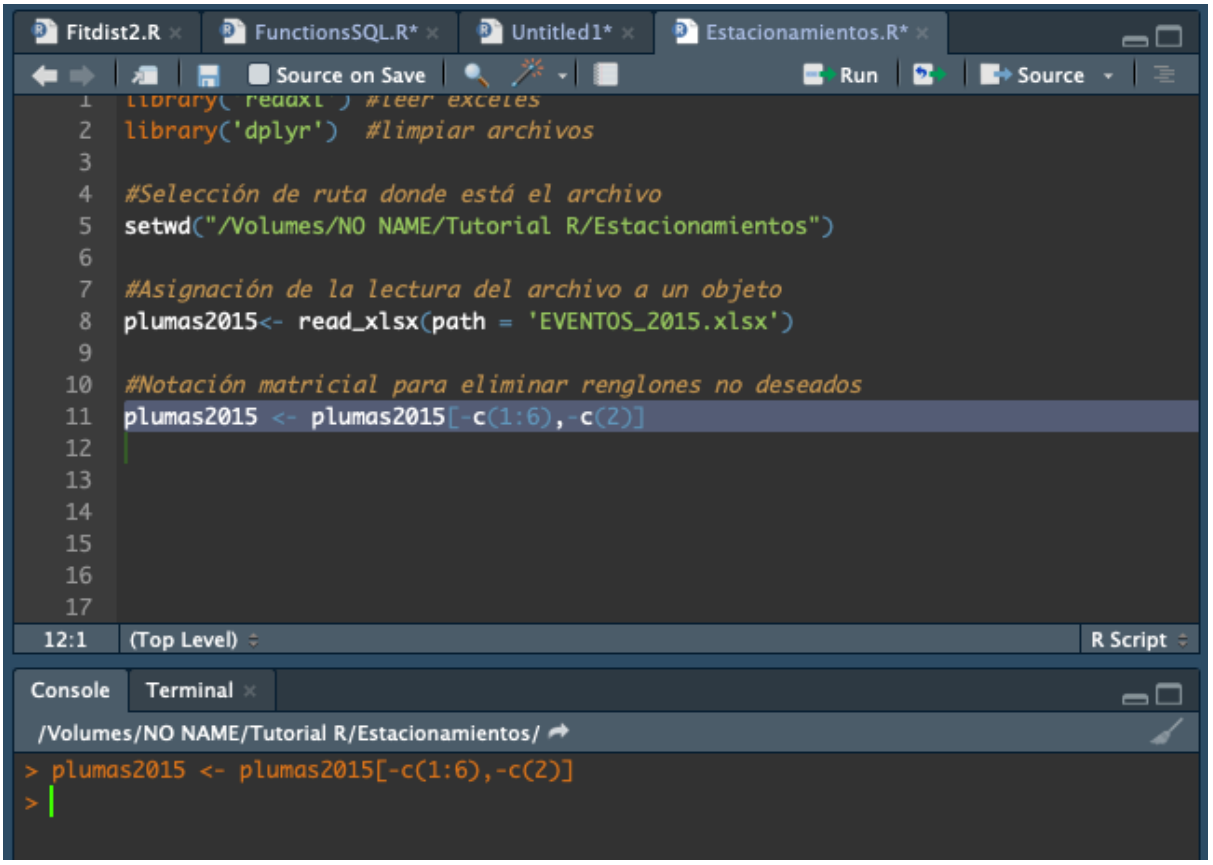

(Figura Caso 1.4) En el script se selecciona la línea de código y con ctrl + enter se ejecuta en la consola.

Al volver a correr el siguiente comando, se observa como los renglones no deseados ya no forman parte de nuestro objeto plumas2015, asimismo, se puede apreciar que en la línea 1 están los nombres de los encabezados del set de datos. (Ver figura Caso 1.4):

```
head(plumas2015)
```

(Figura Caso 1.4) Por debajo de los encabezados se observa el tipo de variable <chr> carácter.

Con el siguiente comando se define el primer renglón como el nombre de las variables o encabezado del set de datos.

```
colnames(plumas2015)<-plumas2015[1,]
```

Ahora que se observa que el primer renglón del set de datos corresponde al encabezado, puede ser eliminado el renglón. En cualquier momento podemos dar un vistazo al encabezado del set de datos con la función head() (Ver figura Caso 1.5)

```
plumas2015 <- plumas2015[-c(1),]
```

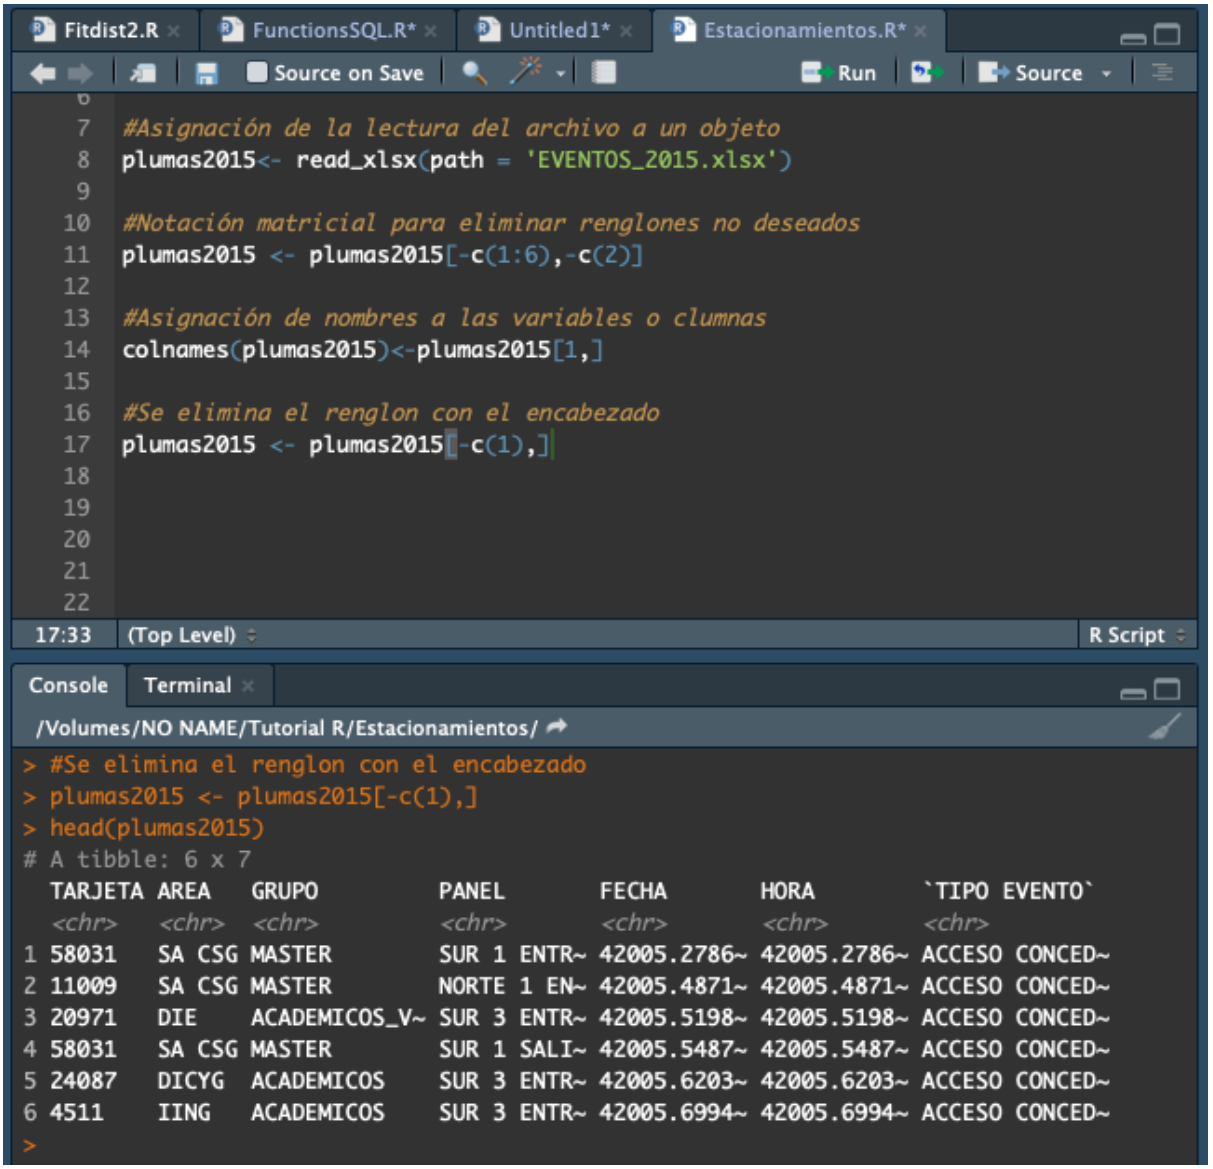

(Figura Caso 1.5) la función head() muestra el estado actual del objeto plumas2015 después de las modificaciones ejecutadas sobre este.

Continuando con la fase de limpieza de datos, observe como la columna tarjeta tiene datos de tipo numérico, pero son tratados como caracteres. Además, la columna de fecha y hora está en formato numérico. El codigo mostrado a continuación, se asigna el formato correcto a cada variable:

```
plumas2015$TARJETA <- as.numeric(plumas2015$TARJETA)
```

3.4 Transformación de datos

Para asignar el formato correcto a las columnas de fecha y hora existe la función *as.POSIXct* el cual es un estándar que puede manejar unidades de tiempo, con una definición de años a segundos. Para poder usar esta función, primero se convertirán las variables de tipo carácter a tipo numérico, posteriormente se asignará la zona horaria para evitar errores de conversión. (Ver figura Caso 1.7)

```
plumas2015$FECHA <- as.numeric(plumas2015$FECHA)

plumas2015$FECHA <-
as.POSIXct(as.Date(plumas2015$FECHA,origin="1899-12-30"))
attr(plumas2015$FECHA,"tzone") <- "UTC"

plumas2015$FECHA <- as.Date(plumas2015$FECHA)
```

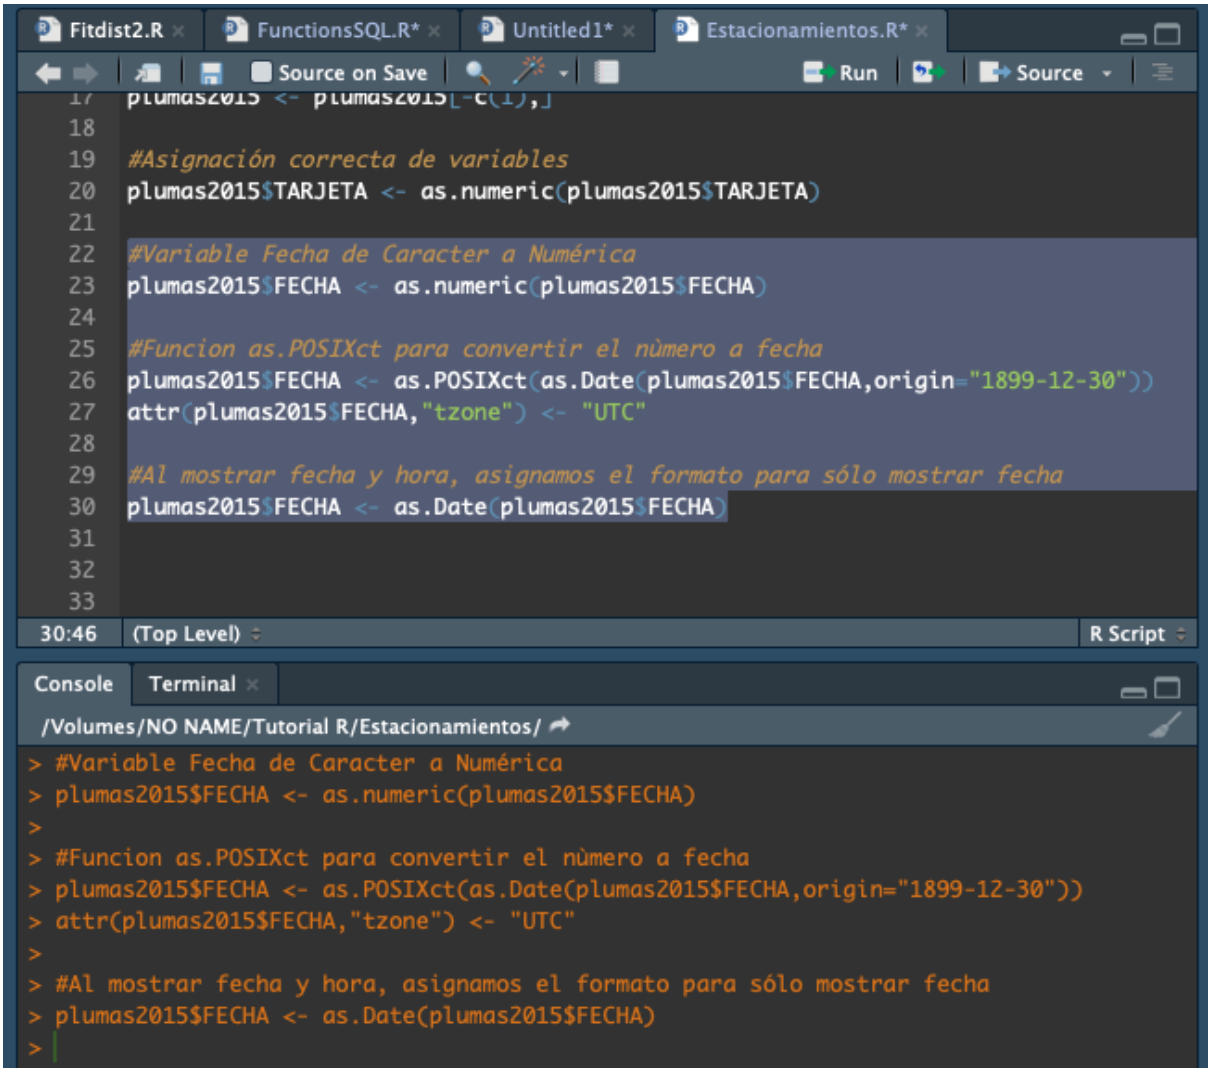

(Figura Caso 1.7) Nuevamente, el código seleccionado se ejecuta si presionamos ctrl + enter.

Un problema común es que mientras en excel las fechas tienen un formato en la hoja de cálculo, al momento de ser escritas en un archivo son escritas como número. Este tipo de errores pueden o no llegar a ser frecuentes y es una buena forma de mostrar el poder de la colaboración en la programación, plataformas sociales como *Stackoverflow* sirven para preguntar este tipo de problemas particulares. (Ver figura Caso 1.8)

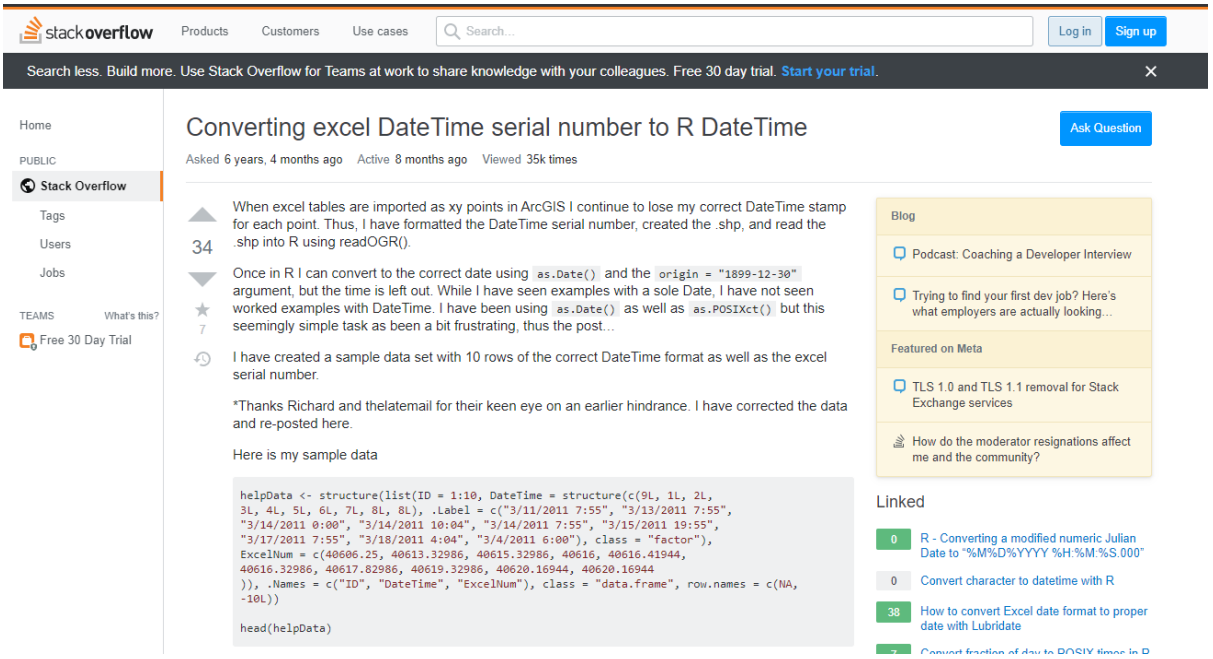

(Figura Caso 1.8) Sitio web StackOverflow[12].

Con la variable horas se realiza algo similar, con la diferencia de que el formato usado será el de HH:MM:SS

Como siempre, es útil usar el comando head para ver el resultado de las instrucciones arriba mencionadas (Ver figura Caso 1.9)

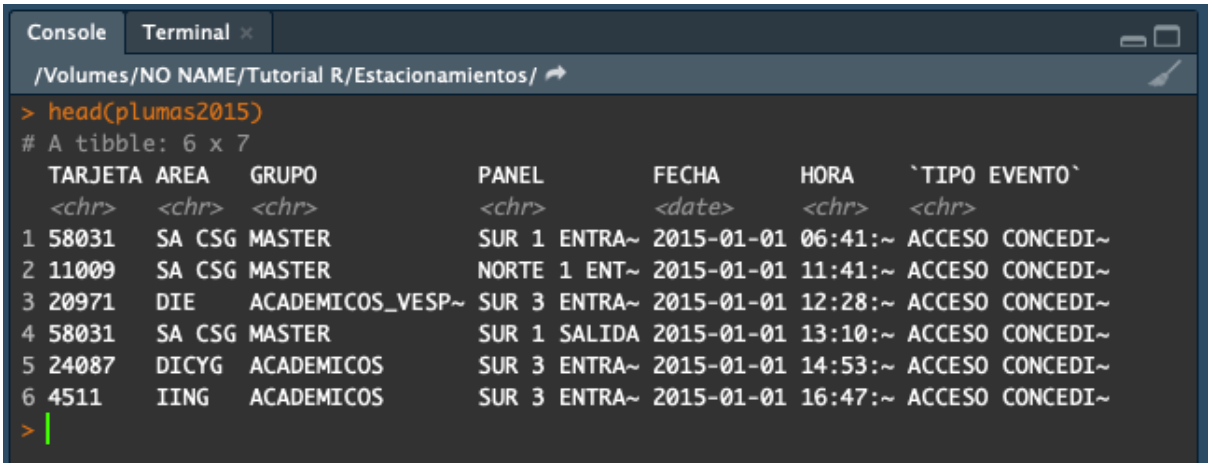

(Figura Caso 1.9) Observe como la columna fecha es un dato <date>.

[12] Converting excel DateTime serial number to R DateTime - Stack Overflow

3.5 Visualización de datos

Para tener una vista completa, existe el comando View() que abre una nueva pestaña en la ventana Source Editor (Ver figura Caso 1.10)

```
View(plumas.total)
```

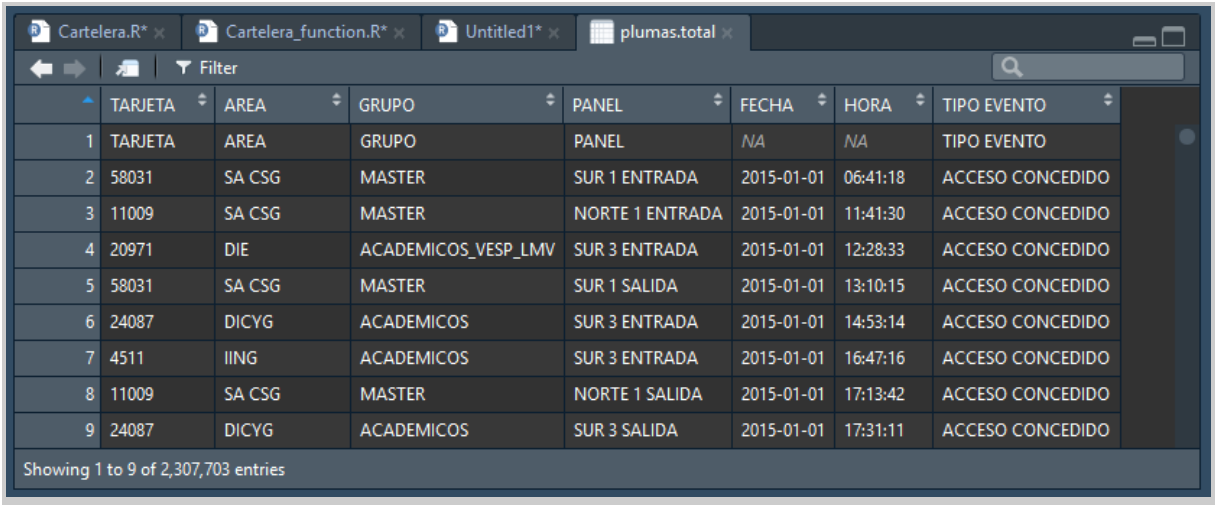

Cartelera.R* | Cartelera_function.R* | Untitled1* | plumas.total

Filter

	TARJETA	AREA	GRUPO	PANEL	FECHA	HORA	TIPO EVENTO
1	TARJETA	AREA	GRUPO	PANEL	*NA*	*NA*	TIPO EVENTO
2	58031	SA CSG	MASTER	SUR 1 ENTRADA	2015-01-01	06:41:18	ACCESO CONCEDIDO
3	11009	SA CSG	MASTER	NORTE 1 ENTRADA	2015-01-01	11:41:30	ACCESO CONCEDIDO
4	20971	DIE	ACADEMICOS_VESP_LMV	SUR 3 ENTRADA	2015-01-01	12:28:33	ACCESO CONCEDIDO
5	58031	SA CSG	MASTER	SUR 1 SALIDA	2015-01-01	13:10:15	ACCESO CONCEDIDO
6	24087	DICYG	ACADEMICOS	SUR 3 ENTRADA	2015-01-01	14:53:14	ACCESO CONCEDIDO
7	4511	IING	ACADEMICOS	SUR 3 ENTRADA	2015-01-01	16:47:16	ACCESO CONCEDIDO
8	11009	SA CSG	MASTER	NORTE 1 SALIDA	2015-01-01	17:13:42	ACCESO CONCEDIDO
9	24087	DICYG	ACADEMICOS	SUR 3 SALIDA	2015-01-01	17:31:11	ACCESO CONCEDIDO

Showing 1 to 9 of 2,307,703 entries

(Figura Caso 1.10)

Los siguientes bloques de código utilizan el método pipe notation[13], en el cual se encadenan instrucciones con los caracteres “%>%” de esta manera dado un set de datos o dataframe se ejecutan diferentes acciones. Por ejemplo, para conocer los tipos de acceso, se seleccionan las columnas Tarjeta, Panel y Tipo Evento, después se agrupan por Panel y después se cuentan los Tipo Evento, esto en código en R luce de la siguiente manera:

```
#tipos de acceso
a<-(plumas.total %>%
    select(TARJETA,PANEL,`TIPO EVENTO`) %>%
      group_by(PANEL) %>%
      count(`TIPO EVENTO`)
    )
```

[13] 4 Pipes | The tidyverse style guide

```
> #tipos de acceso
> a<-(plumas.total %>%
+       select(TARJETA,PANEL,TIPO.EVENTO) %>%
+       group_by(PANEL) %>%
+       count("TIPO.EVENTO")
+ )
> a
                                        TIPO.EVENTO    freq
1                                             33253     113
2                                  ACCESO CONCEDIDO 2277809
3                     ACCESO DENEGADO ANTIPASSBACK   15460
4                   ACCESO DENEGADO FECHA INVALIDA   11472
5                 ACCESO DENEGADO TARJETA INACTIVA     135
6 ACCESO DENEGADO USUARIO DESCONOCIDO EN EL PANEL    2712
7                                       TIPO EVENTO       2
>
```

(Figura Caso 1.11)

```
#grupos de acceso
g<-(plumas.total %>%
      select(TARJETA,PANEL,GRUPO) %>%
      group_by(PANEL) %>%
      count(GRUPO)
)
```

```
> g<-(plumas.total %>%
+       select(TARJETA,PANEL,GRUPO) %>%
+       group_by(PANEL) %>%
+       count("GRUPO")
+ )
> g
                      GRUPO    freq
1                 ACADEMICOS 1369577
2          ACADEMICOS_MAT_LMV   58748
3            ACADEMICOS_MAT_MJ   31256
4          ACADEMICOS_MATUTINO   42388
5          ACADEMICOS_VESP_LMV   15801
6            ACADEMICOS_VESP_MJ   22319
7        ACADEMICOS_VESPERTINO   26168
8          ACADEMICOS_VIERNES       6
9       ADMINISTRATIVOS_NORTE  280316
10 ADMINISTRATIVOS_NORTE_SUR   54463
11       ADMINISTRATIVOS_SUR  201331
12  ADMINISTRATIVOS_SUR_SUR3    2109
13                  ESPECIAL     213
14             ESPECIAL_SUR_1    9483
15             ESPECIAL_SUR_3     339
16           ESPECIAL_VIE_SAB   11842
17      ESTACIONAMIENTOS SUR     137
18    ESTACIONAMIENTOS_NORTE   11875
19                    GRUPO       2
20                   Master  114077
21                   MASTER   54769
22                   SABADO       6
23                     SUR4     478
>
```

(Figura Caso 1.12)

```
#fechas de acceso
f_entrada<-(plumas.total %>%
      select(TARJETA,PANEL,FECHA,HORA,TIPO.EVENTO) %>%
      filter(TIPO.EVENTO == "ACCESO CONCEDIDO") %>%
      filter(PANEL == "SUR 1 ENTRADA") %>%
      group_by(PANEL,TARJETA, FECHA, HORA) %>%
      arrange(FECHA)
)
```

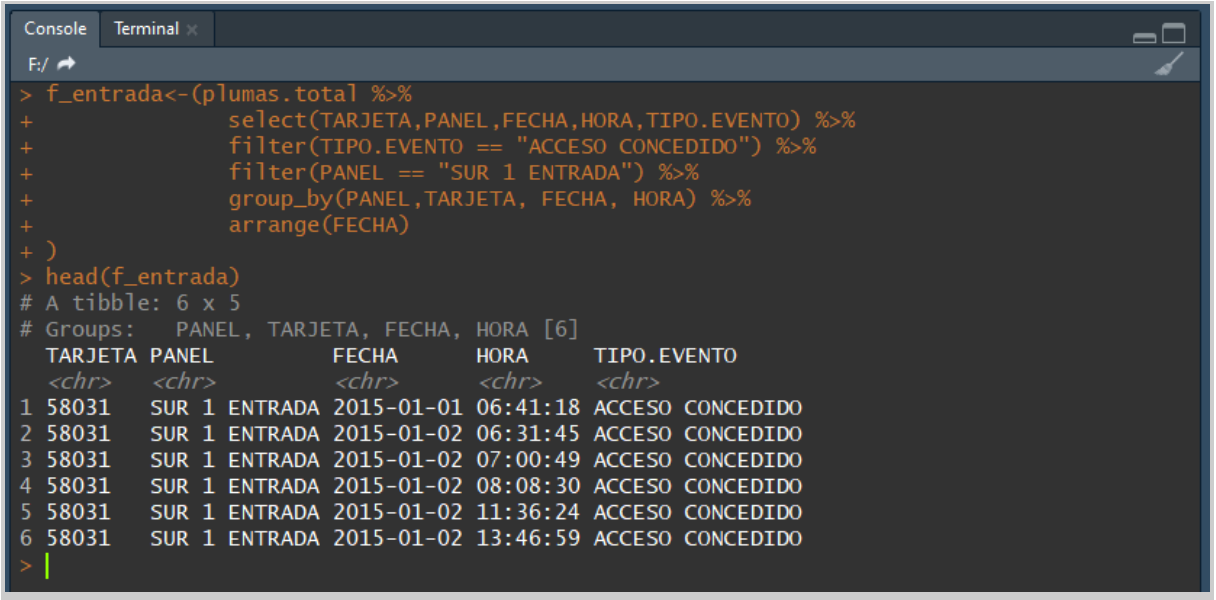

(Figura Caso 1.13)

```
f_salida<-(plumas.total %>%
              select(TARJETA,PANEL,FECHA,HORA,TIPO.EVENTO) %>%
              filter(TIPO.EVENTO == "ACCESO CONCEDIDO") %>%
              filter(PANEL == "SUR 1 SALIDA") %>%
              filter(TARJETA == 11001) %>%
              group_by(PANEL,TARJETA, FECHA, HORA) %>%
              arrange(FECHA) %>%
              count(TIPO.EVENTO)
)
```

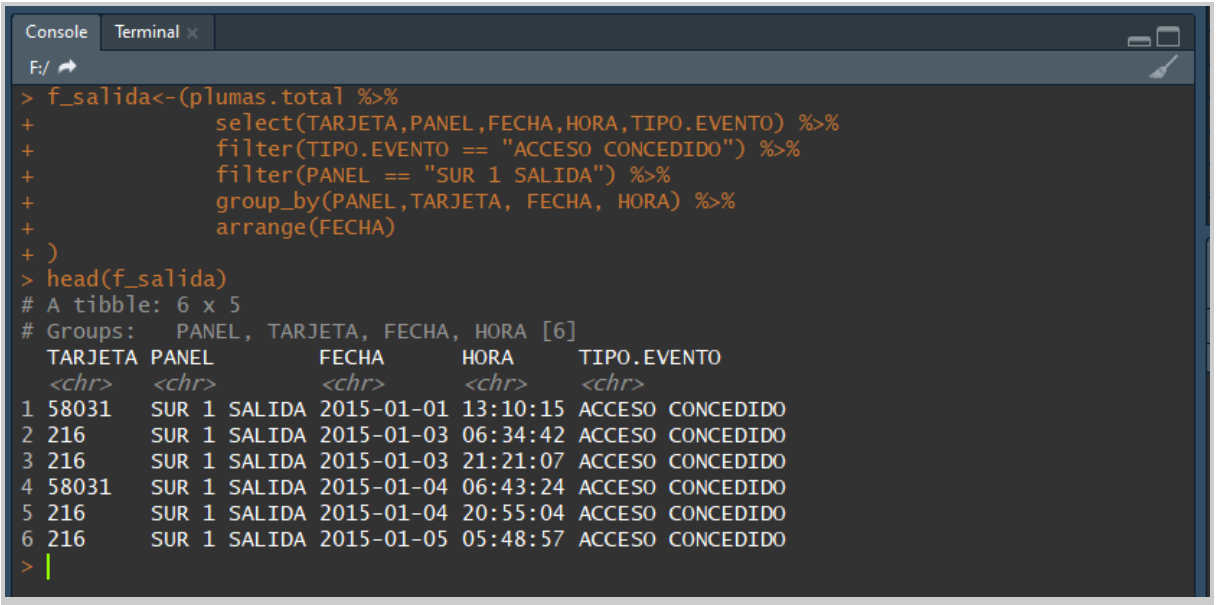

(Figura Caso 1.14)

```
names(f_salida)[4] <- "HORA_SALIDA"
names(f_entrada)[4] <- "HORA_ENTRADA"

estacionamientos <-
left_join(f_entrada,f_salida,by=c("TARJETA","FECHA"))



write.csv(x = plumas.total,file =
"EstacionamientosTotal.csv",quote = FALSE,col.names = TRUE)
```

4. Caso de Estudio 2: Datos de Inmuebles

4.1 Objetivo

El objetivo en este caso de estudio es realizar un análisis exploratorio para conocer qué tan limpia luce la información, convertir sólo los valores en dólares a pesos y realizar un análisis que permita determinar qué operación de compra o renta conviene hacer en cada propiedad en una colonia en particular. Este análisis está basado en una publicación de FORBES[14]:

> *...Como indicador adicional, existe un principio económico llamado Price to rent ratio que puede servir como punto de referencia para determinar si, en cierta zona, es mejor alquilar o comprar. Este se calcula con la relación entre los precios de una vivienda y la renta anual de la misma.*
>
> *Calcular este ratio es bastante simple, básicamente hay que dividir el precio de venta entre la renta anual del inmueble en cuestión. La teoría del Price to rent ratio nos dice que, si el resultado es mayor a 20, es mucho más conveniente rentar que comprar, y si es menor a 15, debes aprovechar la oportunidad de comprar. Si la cifra se encuentra entre 16 y 19, habrá que evaluar otros puntos como el tiempo que planeas vivir en ella, los intereses de tu hipoteca, etc....*

4.2 Importación de Datos

En el conjunto de datos “inmuebles.csv”, hay caracteres especiales con errores de lectura, precios mezclados en dólares y pesos. Para empezar a analizar el set de datos será necesario empezar a escribir algunos de los comandos básicos de exploración en R en la ventana del editor (Ver figura Caso 2.1):

Se identificará el “Working Directory” para asegurar la lectura del archivo correcto.
Se indicará la ruta correcta con el comando setwd()
Se mostrarán los archivos en el directorio de trabajo y se asignan al objeto *Inmuebles* la información contenida en el archivo “inmuebles.csv”

En la ventana de la consola se observa lo que R regresa al correr los comandos de la ventana del editor. (Ver figura Caso 2.1)

[14] ¿Rentar es tirar dinero a la basura?

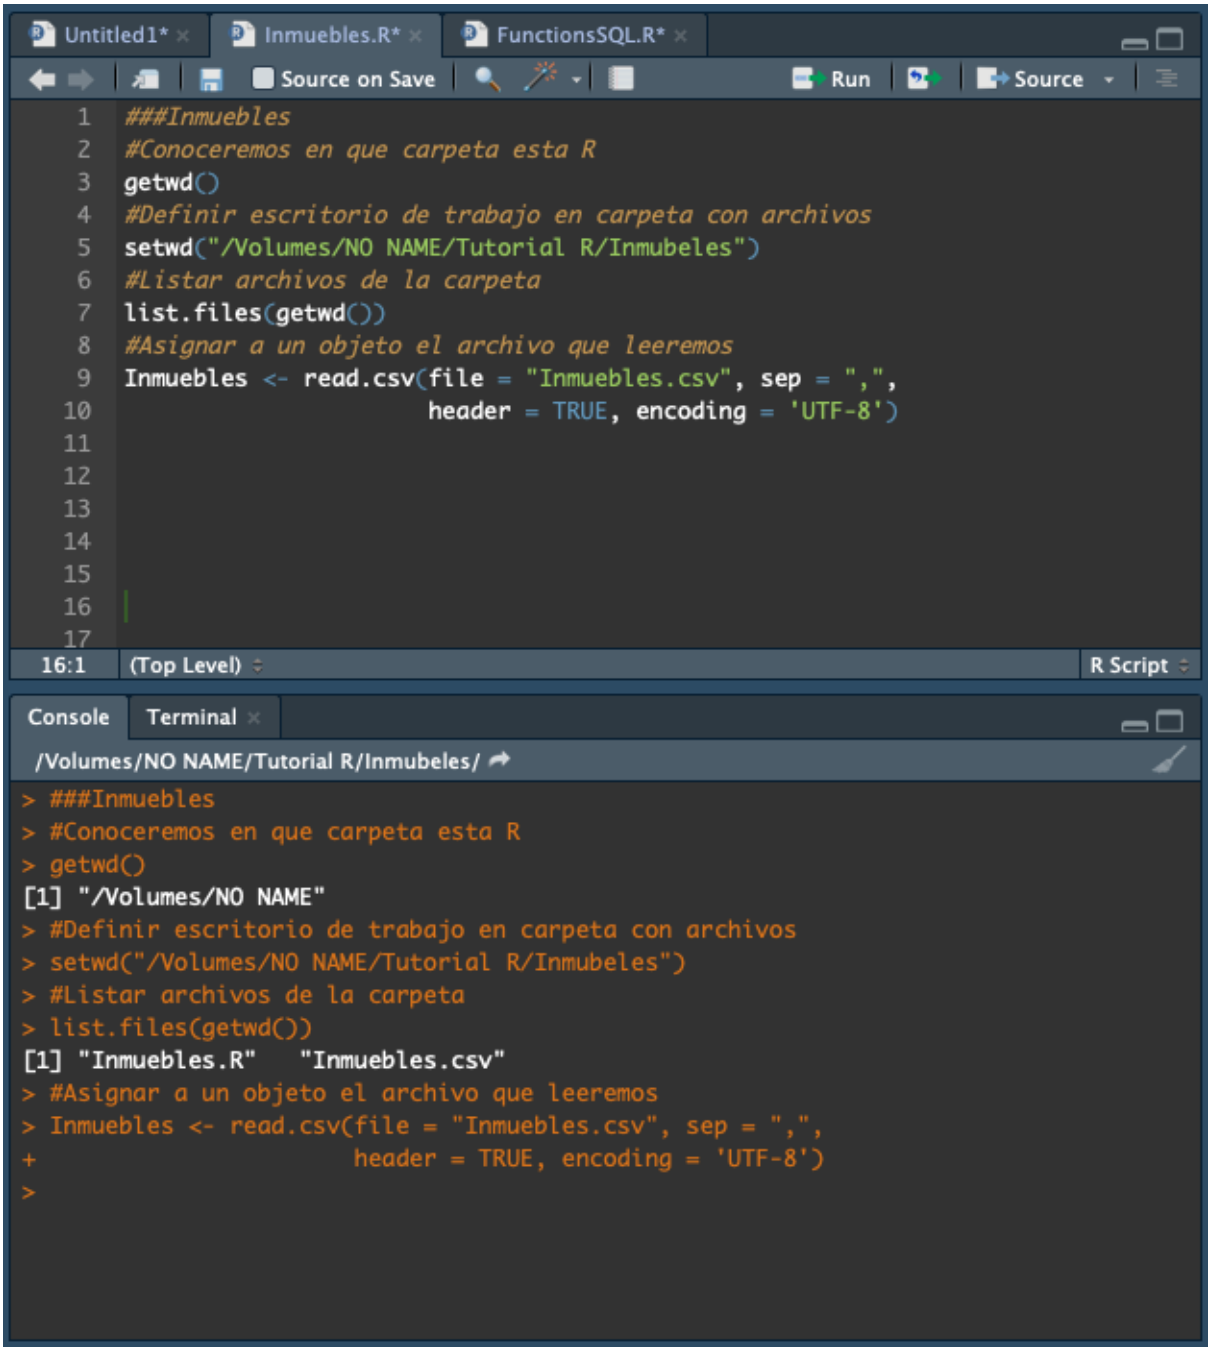

(Figura Caso 2.1) Diálogos de la consola con los archivos del directorio de trabajo.

4.3 Análisis Exploratorio de Datos

Se inicia el análisis exploratorio mostrando el encabezado del archivo “inmuebles.csv” para ello, se usa el siguiente comando:(Ver figura Caso 2.2)

```
head(Inmuebles)
```

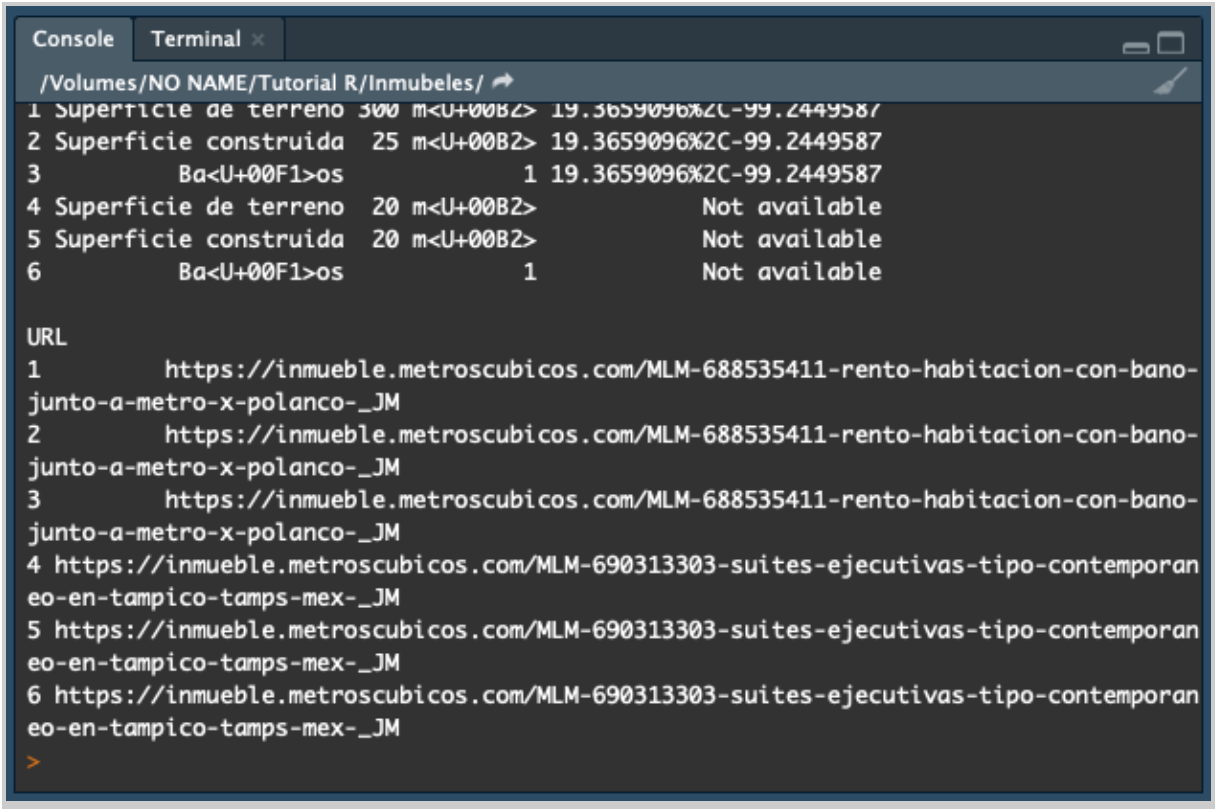

(Figura Caso 2.2) Se observan los datos brutos, es fácil apreciar que se necesitan limpiar.

Es posible conocer más información del archivo como el número de renglones con el comando *nrow()* o el número de columnas con el comando *ncol(),* o bien el tipo de variable del data frame con el comando *str()* o bien los nombres de los encabezados con names*()* (Ver figura Caso 2.3)

```
nrow(Inmuebles)
ncol(Inmuebles)
str(Inmuebles)
names(Inmuebles)
```

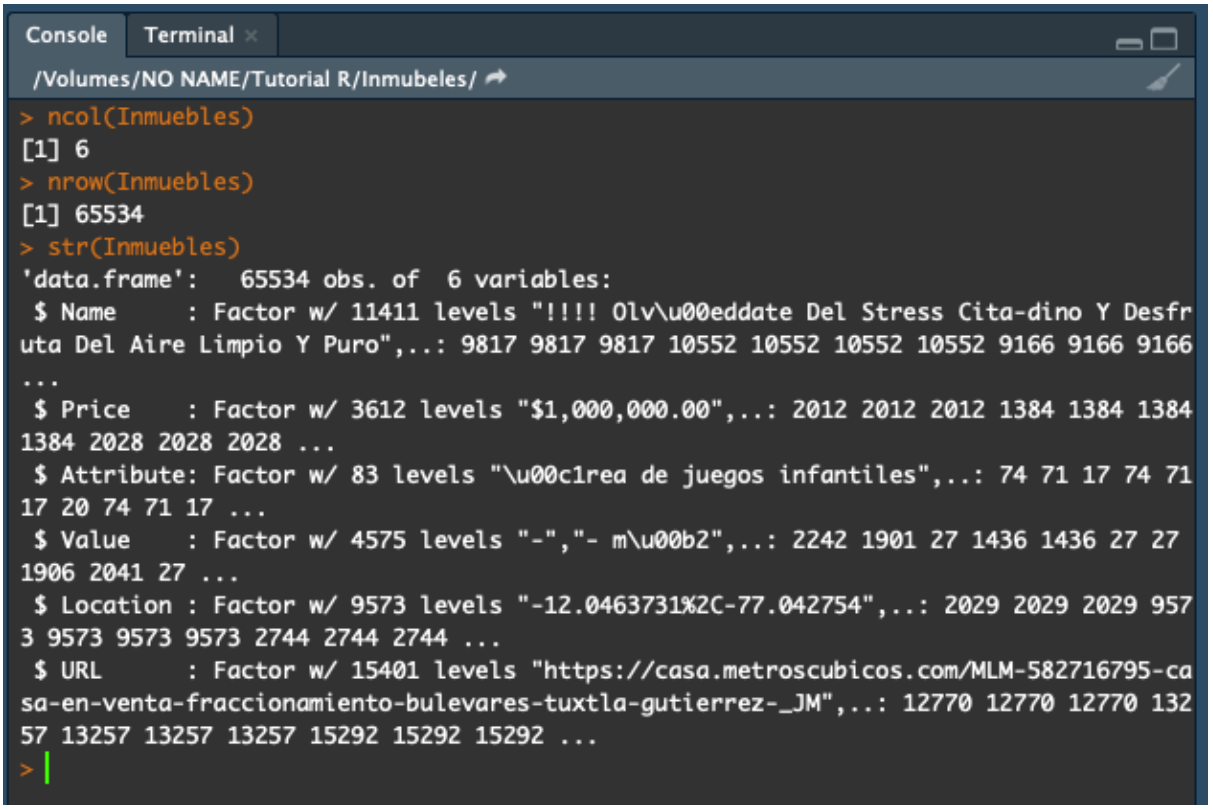

(Figura Caso 2.3) Información acerca del conjunto de datos.

Es posible que existan renglones duplicados, para comprobarlo se ejecuta el comando *unique()* anidado al comando *nrow()*:(Figura Caso 2.4)

(Figura Caso 2.4)

Es evidente que hay líneas duplicadas por lo tanto se escribe en la ventana del editor el siguiente comando que asigna sólo las observaciones sin duplicados al objeto *Inmuebles* que se definió inicialmente, este comando deberá ser ejecutado en la consola de R:
(Ver figura Caso 2.5)

```
Inmuebles <- unique(Inmuebles)
```

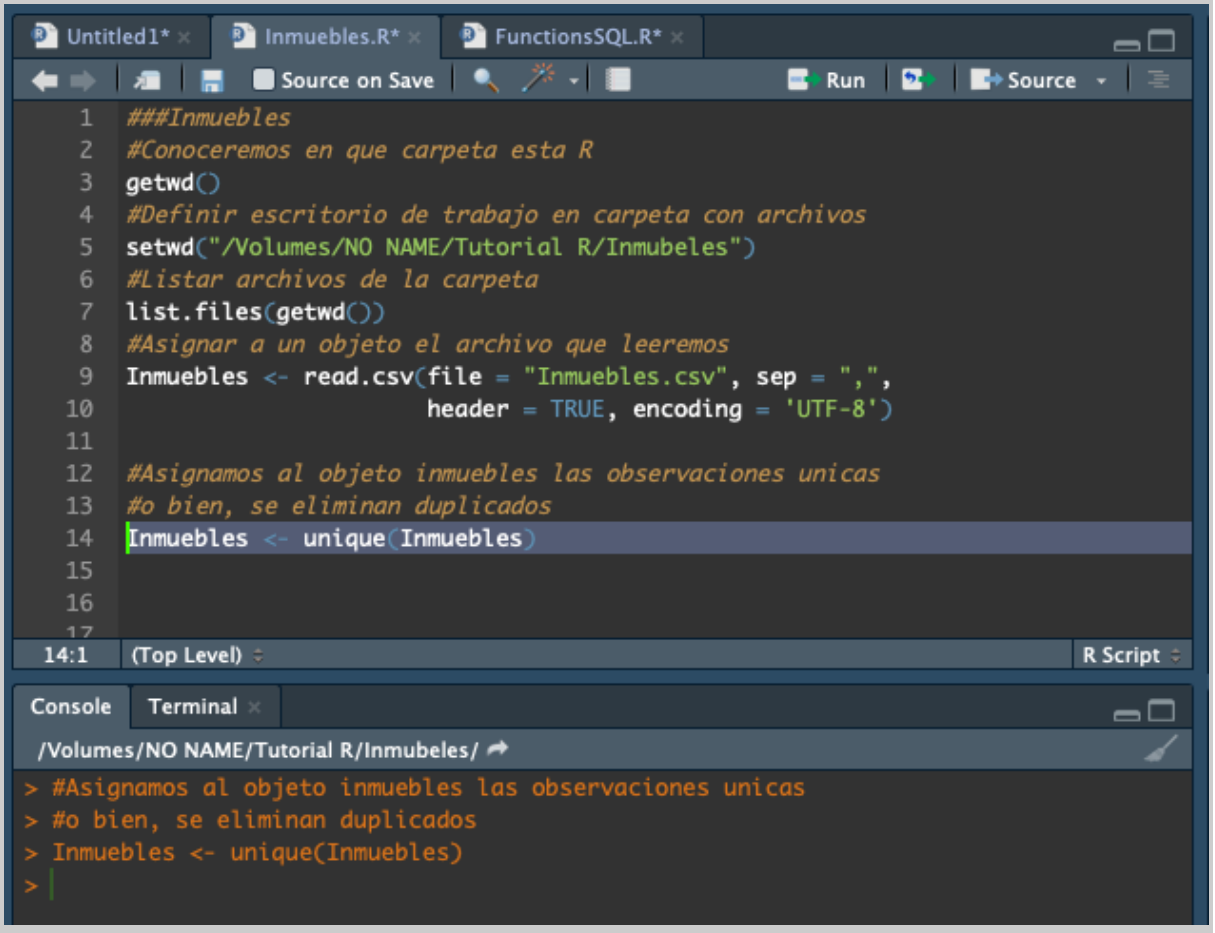

(Figura Caso 2.5) El código existe en el editor y se ejecuta en la ventana de abajo.

Según el resultado presentado en la figura Caso 2.3, todas las variables son factor, es decir, mezcla de números y caracteres por lo tanto no sería posible realizar cálculos como el promedio de precio (Ver figura Caso 2.6):

```
mean(Inmuebles$Price)
```

(Figura Caso 2.6) En esta configuración de Rstudio, los mensajes de error son de otro color.

La razón del error en el promedio es porque los valores de la variable no son numéricos, esto es porque hay caracteres con signos de “$” y “,”. Se recomienda usar la función *gsub()* Donde los argumentos son: (Ver figura Caso 2.7)

pattern Es la cadena de datos que se busca reemplazar
replacement Es el reemplazo de la cadena de caracteres
x Es el objeto al cual se le va a ejecutar la operación

Se escriben los siguientes comandos en la ventana del editor y se corren en la consola.

```
Inmuebles$Price <- gsub(pattern = "\\$", replacement = "", x =
Inmuebles$Price)
Inmuebles$Price <- gsub(pattern = ",", replacement = "", x =
Inmuebles$Price)
Inmuebles$Price <- gsub(pattern = " ", replacement = "", x =
Inmuebles$Price)
```

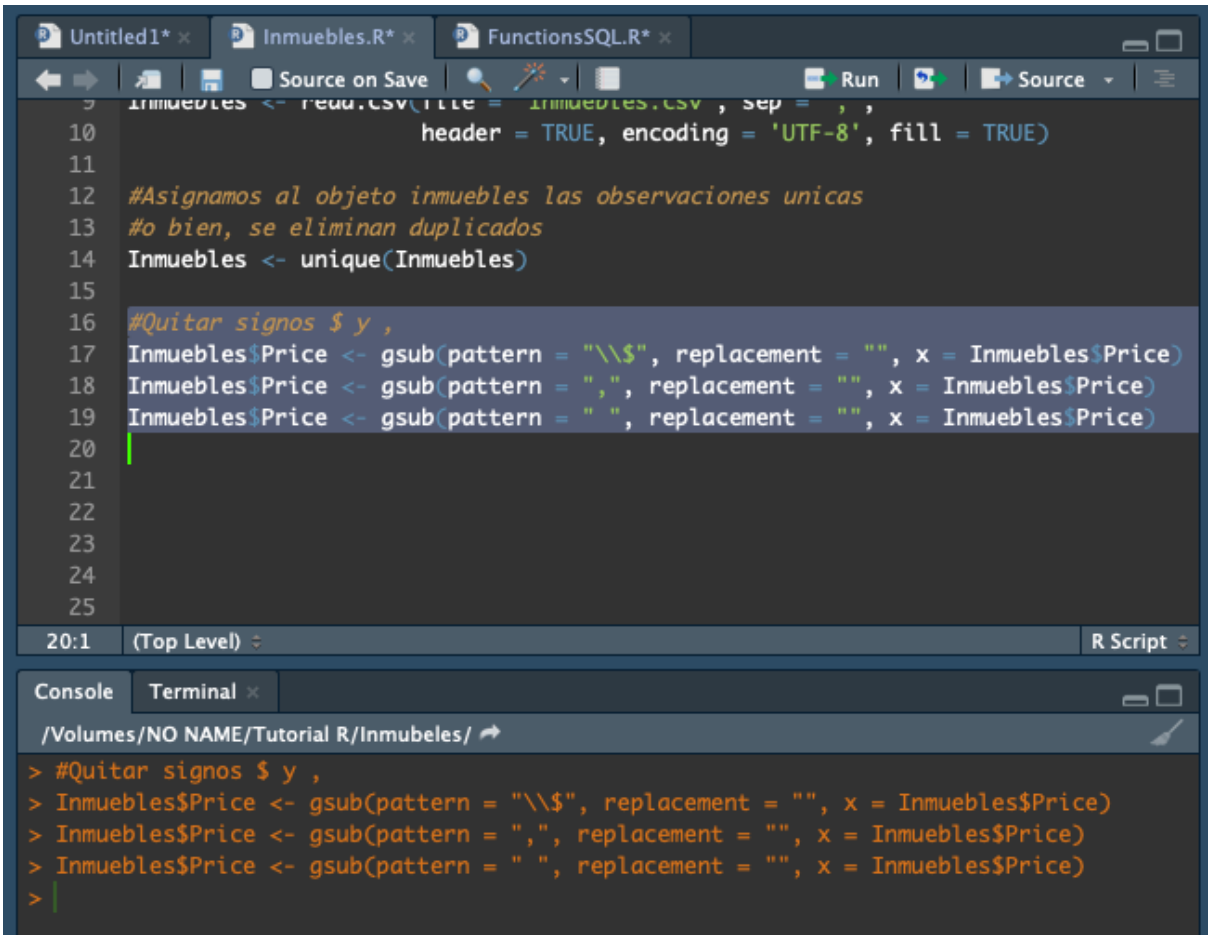

(Figura Caso 2.7) Cada función gsub, sobrescribe al objeto inmuebles.

**Nota, al ser “$” un carácter reservado para operaciones en R, se escribe la anti diagonal. Este problema pudo ser encontrado en stackoverflow[15] de manera similar a la notación de horas del caso de estudio 1.

[15] How do I strip dollar signs ($) from data/ escape special characters in R? - Stack Overflow

Si se intenta calcular el promedio de la variable Price, vuelve a haber un error ahora es porque la columna está en factores. Antes de convertirla a numérico es recomendable usar el comando *View()* para visualizar el set de datos completo y ordenar descendente y ascendente la variable para ver qué tipo de datos hay (Ver figura Caso 2.8)

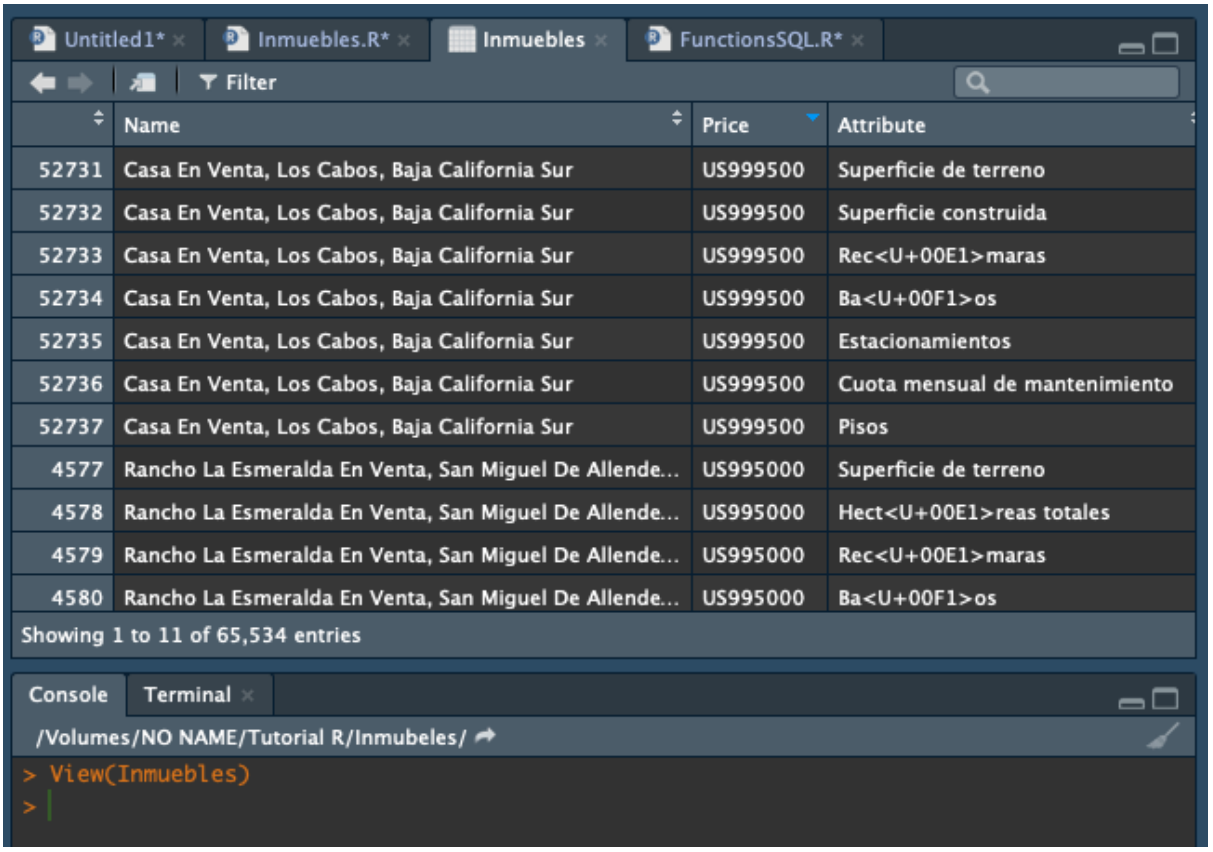

(Figura Caso 2.8) Los datos son ordenados por el valor de Price.

¿Qué hacer con las columnas que están en dólares?
¿Cómo identificar las columnas en dólares para hacer una operación si son dólares y otra si no?

Es posible darse cuenta que hay celdas con US, indicando que son precios en dólares.
La función *grepl()* evalúa en una lista la existencia de un "pattern" o patrón de manera similar a *gsub()* los argumentos son los siguientes:

pattern Es la cadena de datos que se busca reemplazar
x Es el objeto al cual se le va a ejecutar la operación

Corriendo el siguiente comando podemos ver que el resultado de la función *grepl()* indica de los 64K renglones, cuales contienen "US" en modo booleano es decir en Falso y Verdadero: (Ver figura Caso 2.9)

```
grepl(pattern = "US",x = Inmuebles$Price)
```

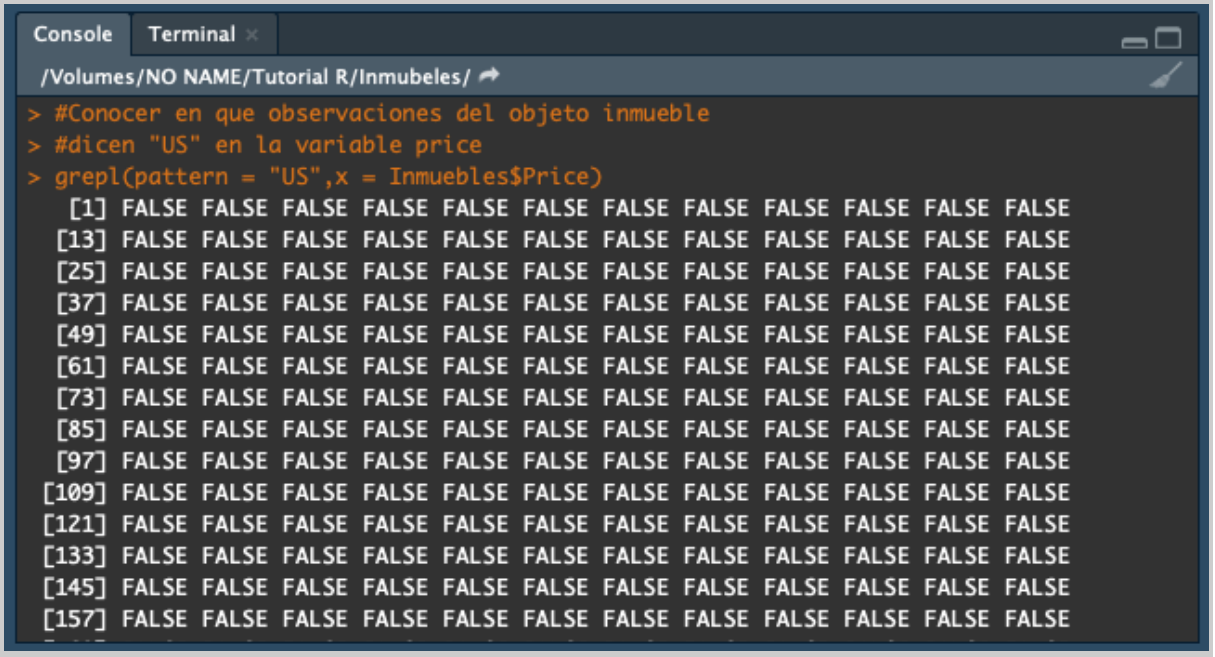

(Figura Caso 2.9) Resultado de la evaluación de cada uno de los elementos del vector Inmuebles$Price.

La función *which()* regresa el index, renglón o número de observación en donde el vector sea TRUE, se anida la función *grepl()* dentro de *which()* (Ver figura Caso 2.10)

```
which(grepl(pattern = "US",x = Inmuebles$Price))
```

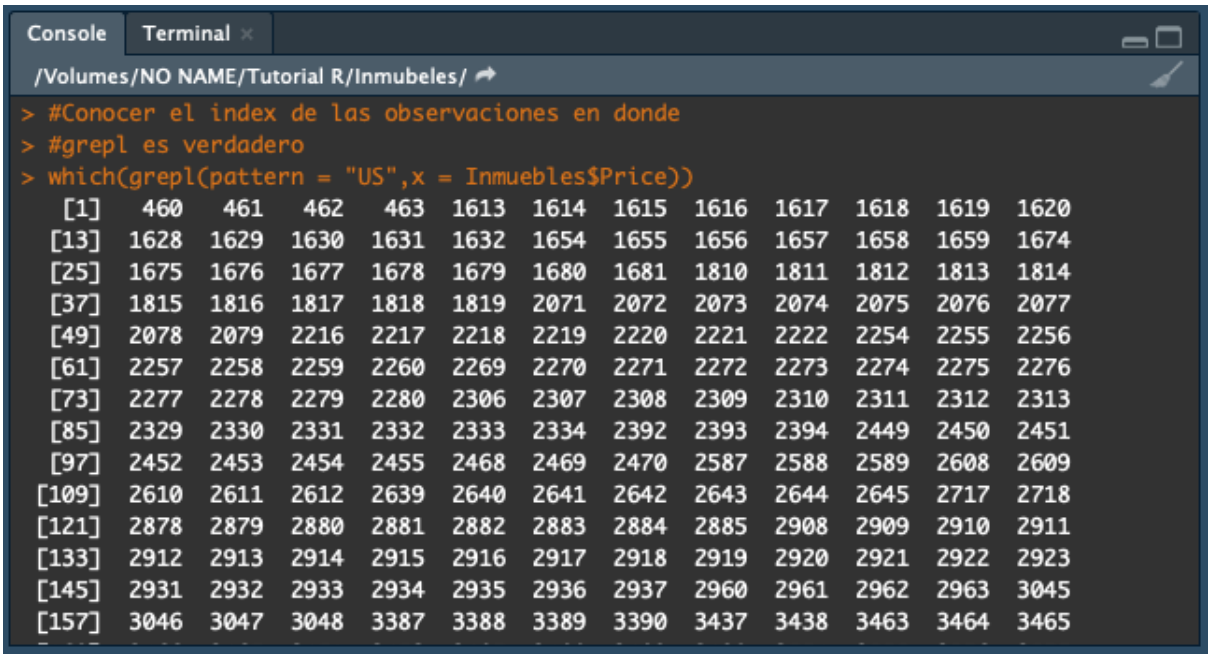

(Ver figura Caso 2.10) Se aprecia en el index las observaciones que fueron evaluadas como TRUE.

Ahora que se conoce cuál es el index, renglón u observación que contiene US, es posible asignar esa lista a un objeto al cuál se le llamará *dlls.* Se escribe el comando en la ventana del editor y se corre en la consola de R (Ver figura Caso 2.11)

```
dlls <- which(grepl(pattern = "US",x = Inmuebles$Price))
```

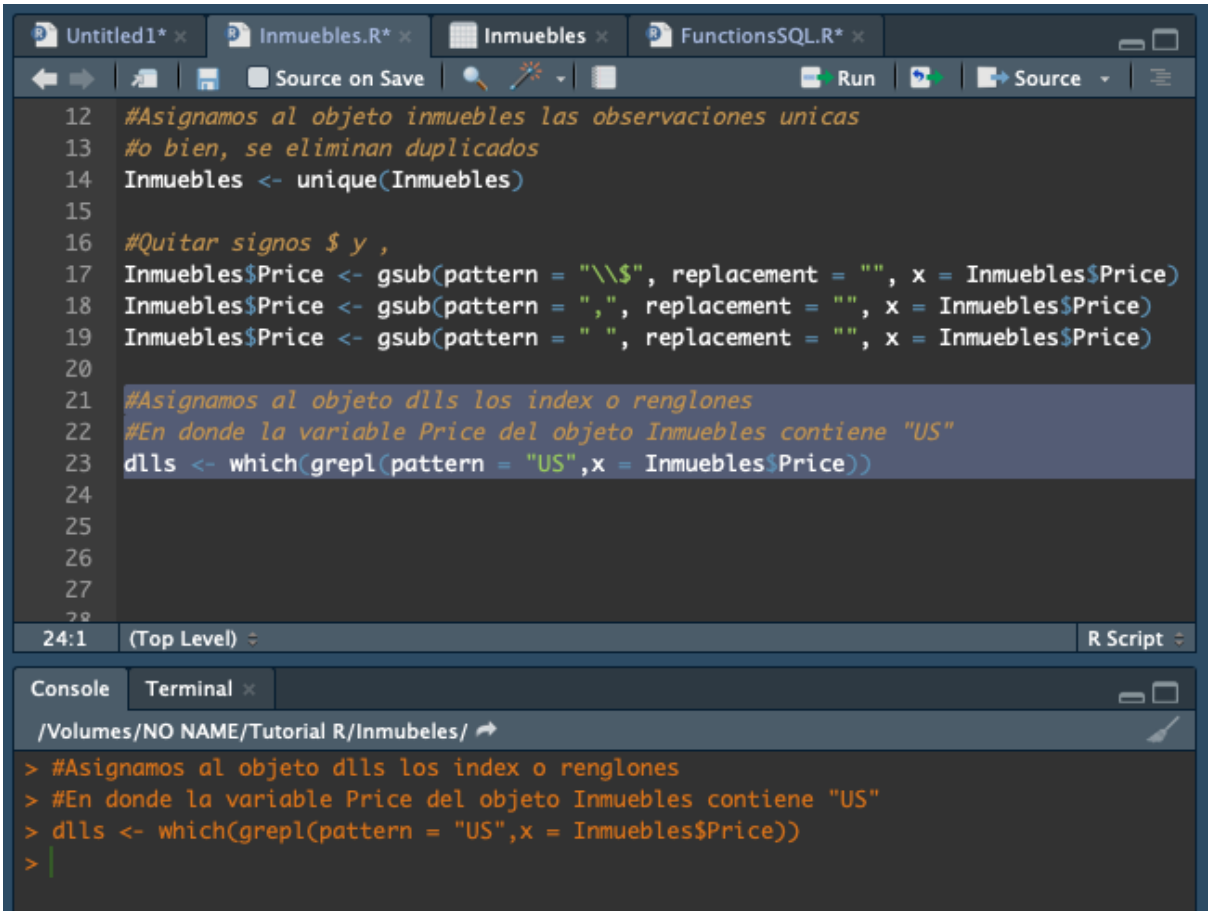

(Figura Caso 2.11) A que el resultado de la función which se asigna a una variable, el resultado no se imprime en pantalla.

Teniendo escrito el index en la variable dlls se elimina el carácter "US" como se realizó con el signo “$” y “,” se escribe el comando en el editor y se corre en la consola de R: (Ver figura Caso 2.12)

```
Inmuebles$Price <- gsub(pattern = "US", replacement = "", x =
Inmuebles$Price)
```

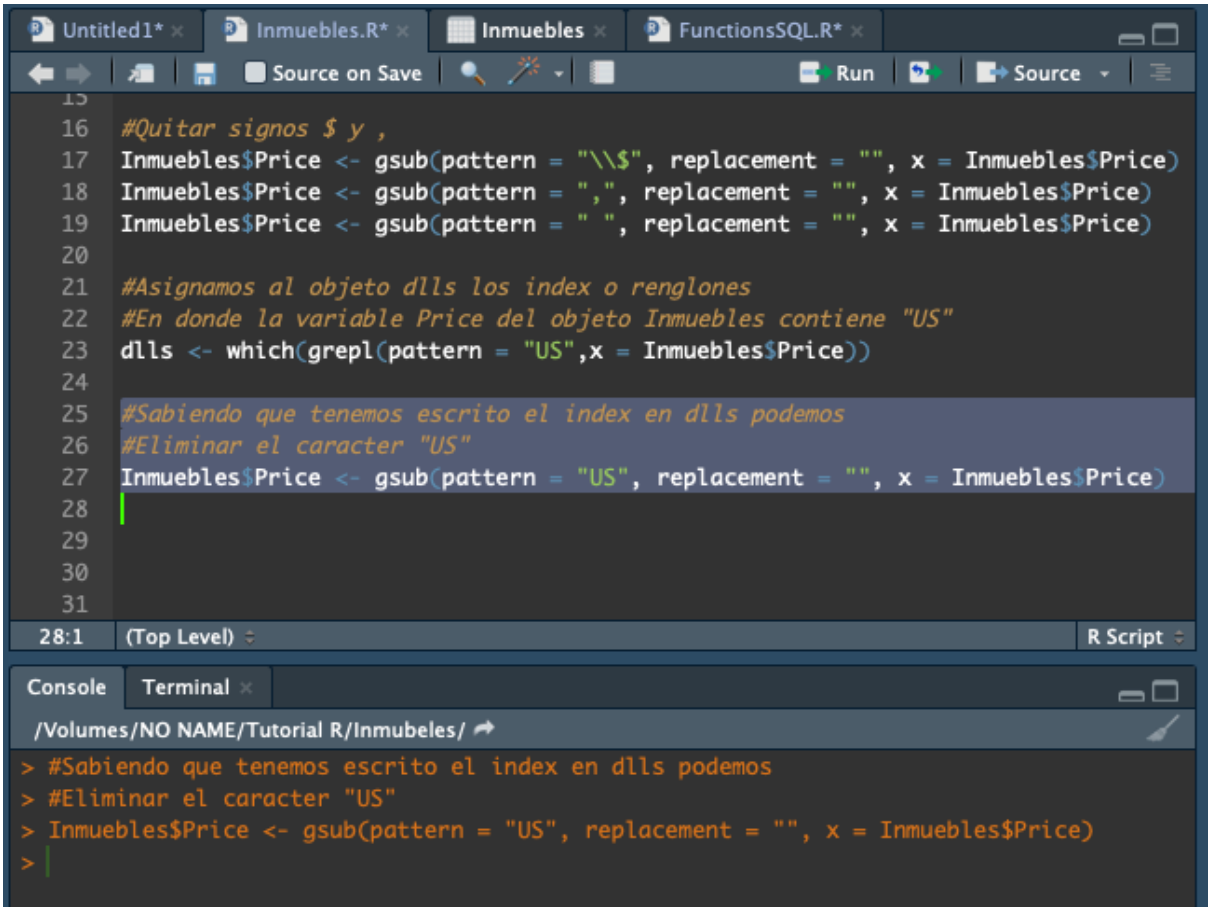

(Figura Caso 2.12) Ahora ya no hay observaciones con el carácter US en los precios.

Sin el carácter "US", es posible multiplicar por el tipo de cambio los precios de las observaciones en dólares (dlls)

En un data frame usamos $ para llamar una columna y entre [] ponemos el index o renglón de los valores que sabemos que están en dólares; por lo tanto la siguiente expresión podrá ser leída como se indica:

```
Inmuebles$Price[dlls]
```

Objeto:Inmuebles
Columna: Price
Renglones: elementos en la variable dlls

De forma equivalente la notación matricial genera el mismo resultado:

```
Inmuebles[dlls,2]
```

Para este ejemplo, se sabe que la columna price es la segunda del Data frame por lo tanto usando la nomenclatura arriba mencionada, se escribe el siguiente comando en la ventana del editor y se corre en la consola de R: (Ver figura Caso 2.13)

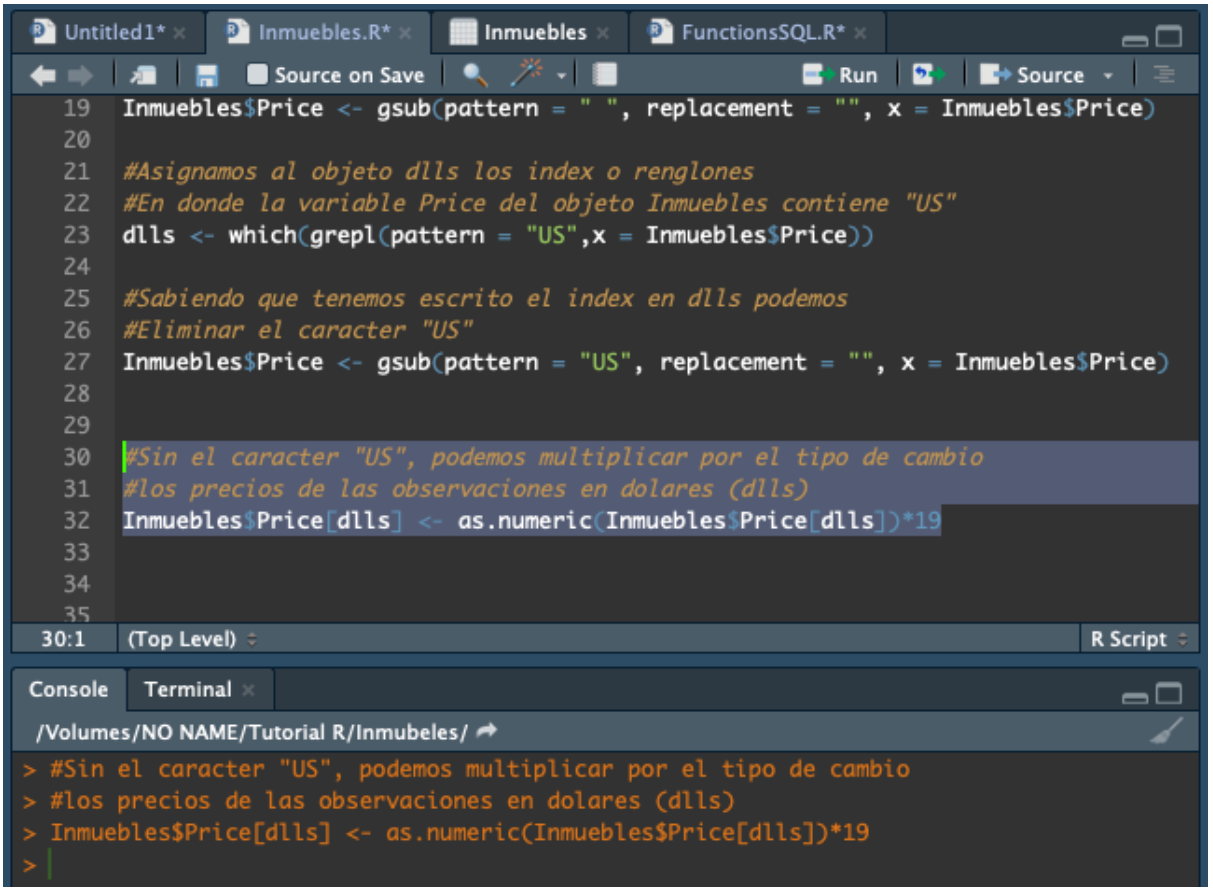

(Figura Caso 2.13) Operación de multiplicar por el tipo de cambio únicamente las columnas etiquetadas con dólares.

```
Inmuebles$Price[dlls] <- as.numeric(Inmuebles$Price[dlls])*19
```

Ahora es posible asignar el tipo de variable numérico a toda la columna usando el comando as.numeric(), se escribe el siguiente comando en la ventana del editor y se corre en la consola de R: (Ver figura Caso 2.14)

```
Inmuebles$Price <- as.numeric(Inmuebles$Price)
```

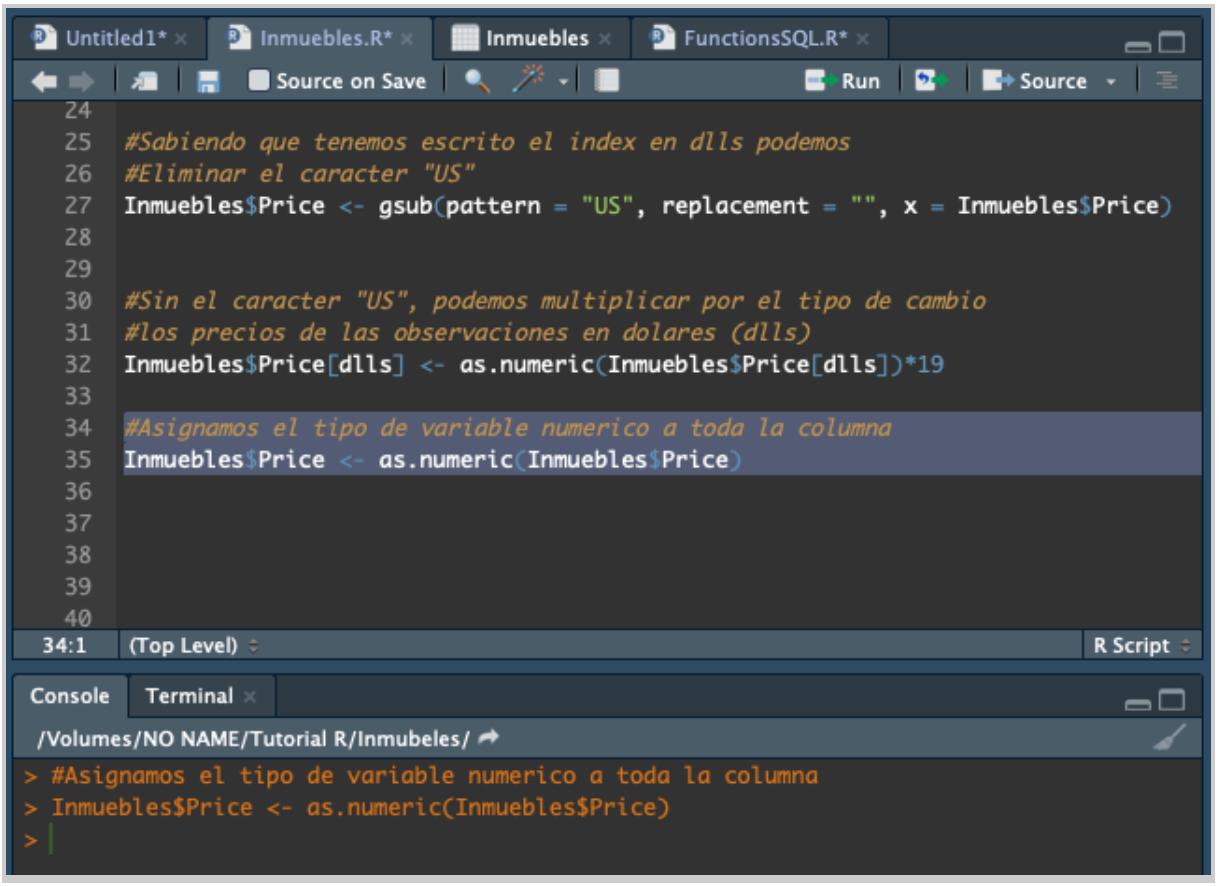

(Figura Caso 2.14) Al haber limpiado la columna Price por completo, ya no hay mensaje de error por cambiar a formato numérico.

Continuando el análisis exploratorio, es posible notar que la latitud y longitud son separadas por la cadena de caracteres "%2C" :(Ver figura Caso 2.15)

```
head(Inmuebles$Location)
```

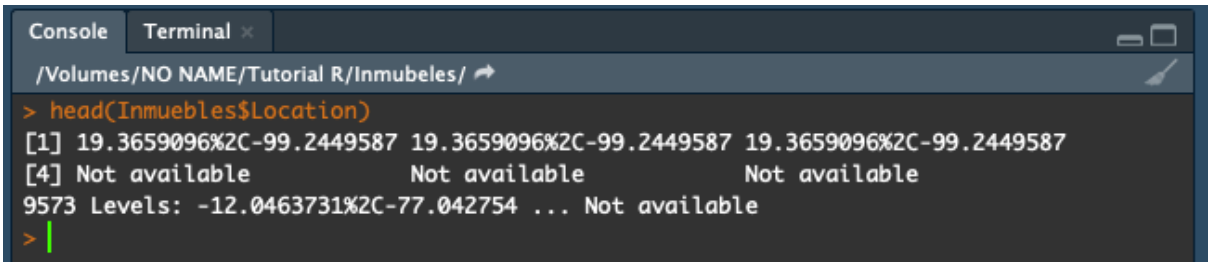

(Figura Caso 2.15)

Para separar una cadena de texto en dos partes, se usa la funciòn *strsplit()*, sin embargo sólo funciona con variables de tipo *character,* es posible anidar la función *as.character()* dentro de *strsplit()* se puede ver el encabezado de esta operación con el siguiente comando: (Ver figura Caso 2.16)

```
head(strsplit(as.character(Inmuebles$Location),"%2C"))
```

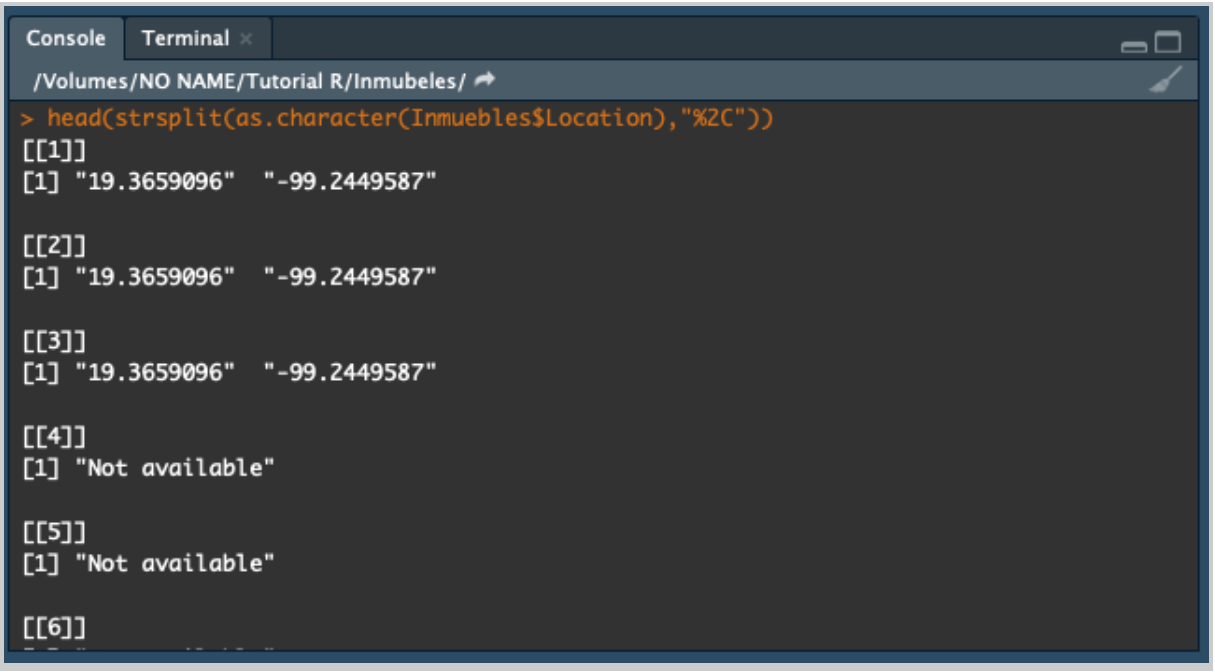

(Figura Caso 2.16) Valores de locación separados por los caracteres %2C.

Es posible observar que la separación de la cadena de caracteres fué exitosa, sin embargo el resultado es una lista de vectores *list*, mientras que el objeto inmuebles es un *data frame* para resolver eso se usa la función *do.call()* con el argumento rbind para tener un data frame: (Ver figura Caso 2.17)

```
LatLong <-
do.call(rbind,strsplit(as.character(Inmuebles$Location),"%2C")
)
Inmuebles$Latitude <- LatLong[,1]
Inmuebles$Longitude <- LatLong[,2]
```

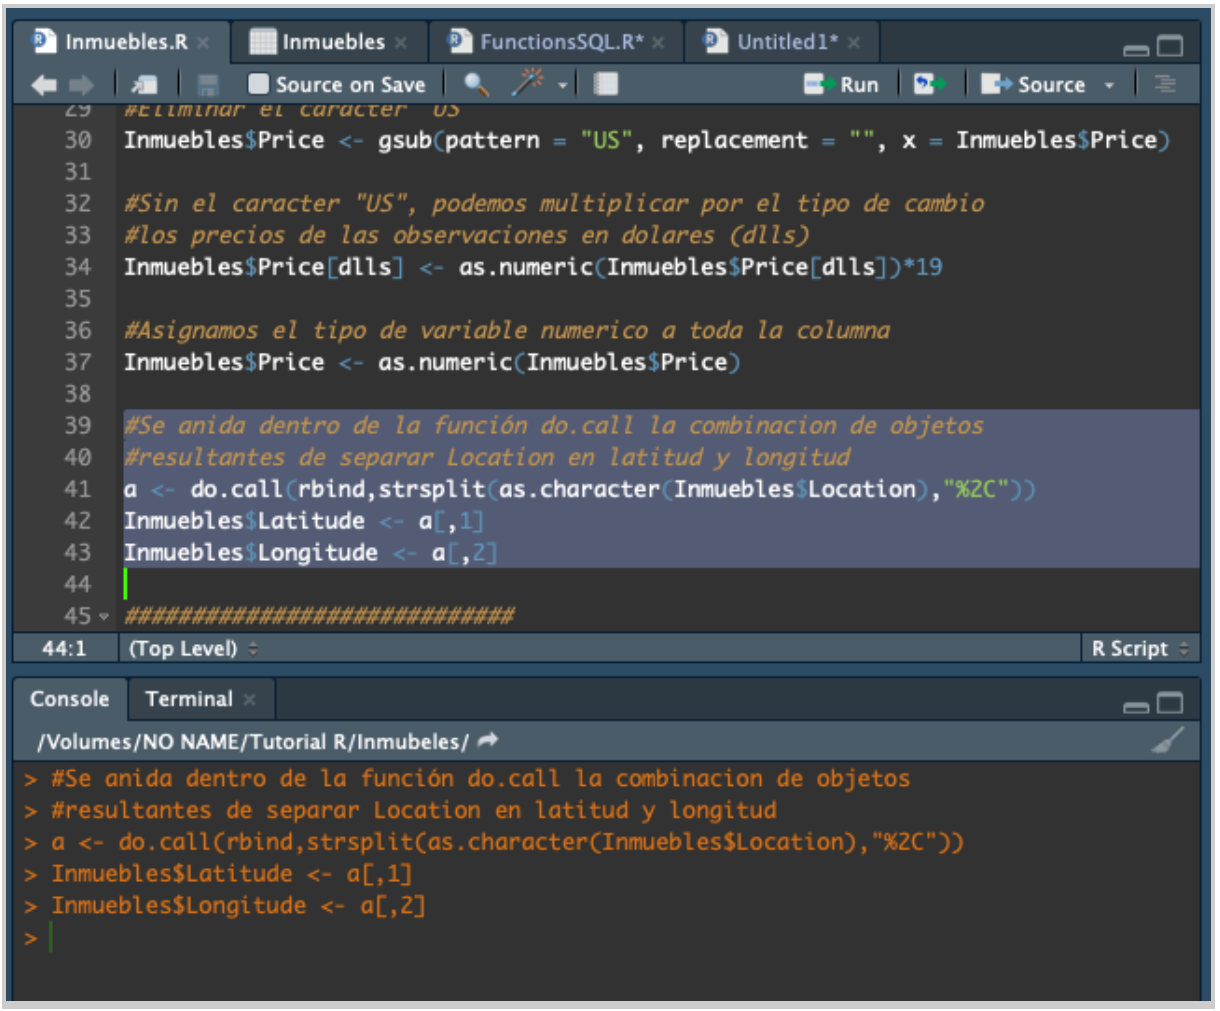

(Figura Caso 2.17) Se generan 2 nuevas variables asignando el resultado de separación de caracteres.

4.4 Código del Caso

Código en lenguaje R del caso 2

```
###Inmuebles
#Conoceremos en que carpeta esta R
getwd()

#Definir escritorio de trabajo en carpeta con archivos
setwd("/Volumes/NO NAME/Tutorial R/Inmubeles")

#Listar archivos de la carpeta
list.files(getwd())

#Asignar a un objeto el archivo que leeremos
Inmuebles <- read.csv(file = "Inmuebles.csv", sep = ",",
                      header = TRUE, encoding = 'UTF-8', fill = TRUE)

#Asignamos al objeto inmuebles las observaciones unicas
#o bien, se eliminan duplicados
```

```
Inmuebles <- unique(Inmuebles)

#Quitar signos $ y ,
Inmuebles$Price <- gsub(pattern = "\\$", replacement = "", x =
Inmuebles$Price)
Inmuebles$Price <- gsub(pattern = ",", replacement = "", x =
Inmuebles$Price)
Inmuebles$Price <- gsub(pattern = " ", replacement = "", x =
Inmuebles$Price)

#Asignamos al objeto dlls los index o renglones
#En donde la variable Price del objeto Inmuebles contiene "US"
dlls <- which(grepl(pattern = "US",x = Inmuebles$Price))

#Sabiendo que tenemos escrito el index en dlls podemos
#Eliminar el caracter "US"
Inmuebles$Price <- gsub(pattern = "US", replacement = "", x =
Inmuebles$Price)

#Sin el caracter "US", podemos multiplicar por el tipo de cambio
#los precios de las observaciones en dolares (dlls)
Inmuebles$Price[dlls] <- as.numeric(Inmuebles$Price[dlls])*19

#Asignamos el tipo de variable numerico a toda la columna
Inmuebles$Price <- as.numeric(Inmuebles$Price)

#Se anida dentro de la función do.call la combinacion de objetos
#resultantes de separar Location en latitud y longitud
a <- do.call(rbind,strsplit(as.character(Inmuebles$Location),"%2C"))
Inmuebles$Latitude <- a[,1]
Inmuebles$Longitude <- a[,2]
```

5. Caso de Estudio 3: Horarios de Películas

5.1 Objetivo

El objetivo en este caso de estudio es trabajar con la librería *Tidyverse* para poder conocer información de valor. Se limpiará un archivo y crear una función que limpie archivos similares y escriba en una base de datos.

Una vez creada la base de datos, se deberán de resolver ciertas preguntas de negocio

5.2 Análisis Exploratorio de Datos

Se realizará un análisis exploratorio con uno de los archivos proporcionados (Ver figura Caso 3.1)

```
#Cargar primer archivo
```

```
setwd("D:/")
list.files(getwd())
cines1 <- read.csv(file = list.files(getwd())[1],sep =
",",header = FALSE)
#Breve vistazo a los datos
head(cines1,10)
tail(cines1,10)
View(cines1)
names(cines1)
```

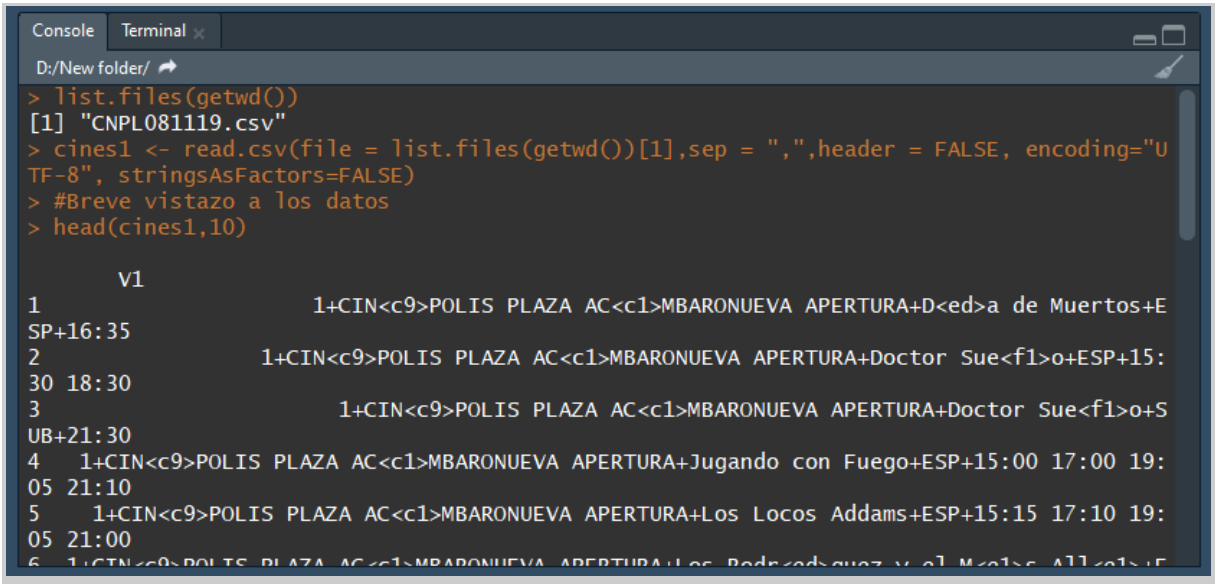

(Figura Caso 3.1) En la exploración de datos, se observa un error de encoding.

Es fácil apreciar que el archivo no es legible, incluso usando el comando View observamos lo siguiente: (Ver figura Caso 3.2)

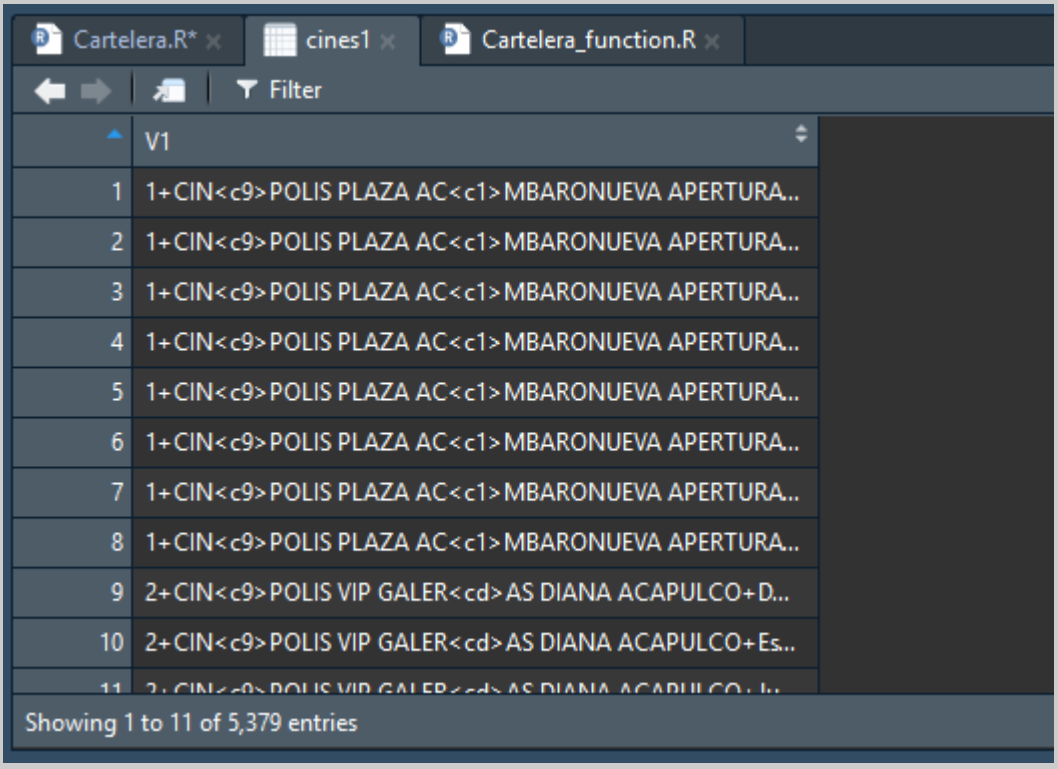

(Ver figura Caso 3.2) Aparentemente todos los datos están en una columna

Se puede observar que las columnas están separadas por el signo + y que hay caracteres especiales como Ñ o acentos; por lo tanto ajustamos la instrucción para leer el archivo: (Ver figura Caso 3.3)

```
#Podemos Ahora volver a cargar el archivo y corregir lo que observamos
cines1 <- read.table(file = "CNPL081119.csv",sep = "+",header = FALSE, stringsAsFactors = FALSE, fill = TRUE)
unique(cines1[,4])
levels(cines1[,4])
head(cines1)
```

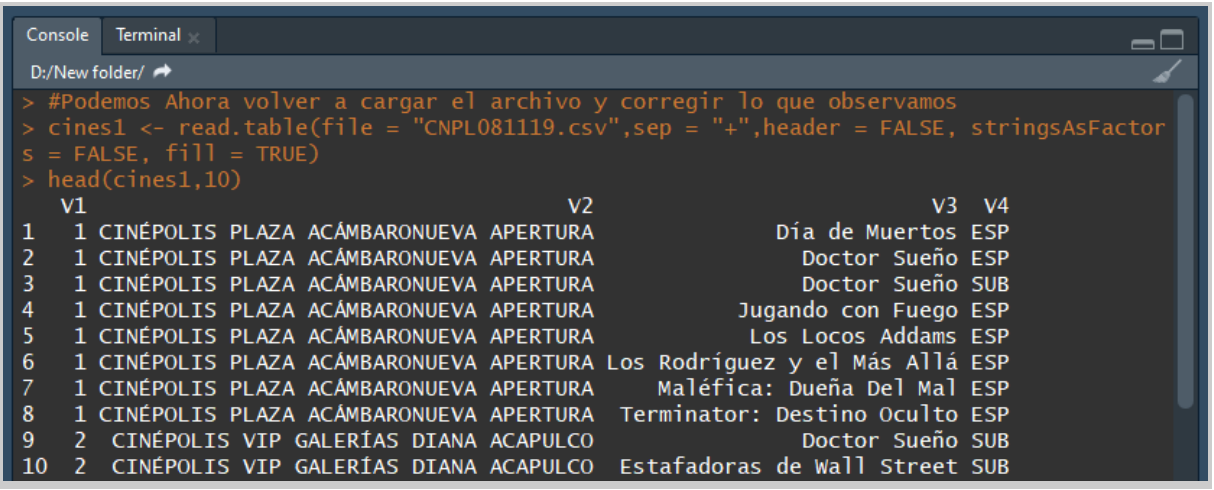

(Figura Caso 3.3) Se aprecia de forma legible el contenido del archivo

```
#Podemos conocer los valores únicos de cada columna
unique(cines1[,4])

names(cines1)
#Al no tener nombres, usamos la notación matricial
```

Así mismo, sabemos que la columnas V1 no tiene información útil para el análisis, le podemos asignar NULL para eliminar la columna, y después nombrar a las columnas con nombres que le corresponden según el dato: (Ver figura Caso 3.4)

```
cines1$V1 <- NULL
names(cines1) <- c("Cine","Pelicula","Idioma","Horarios")
```

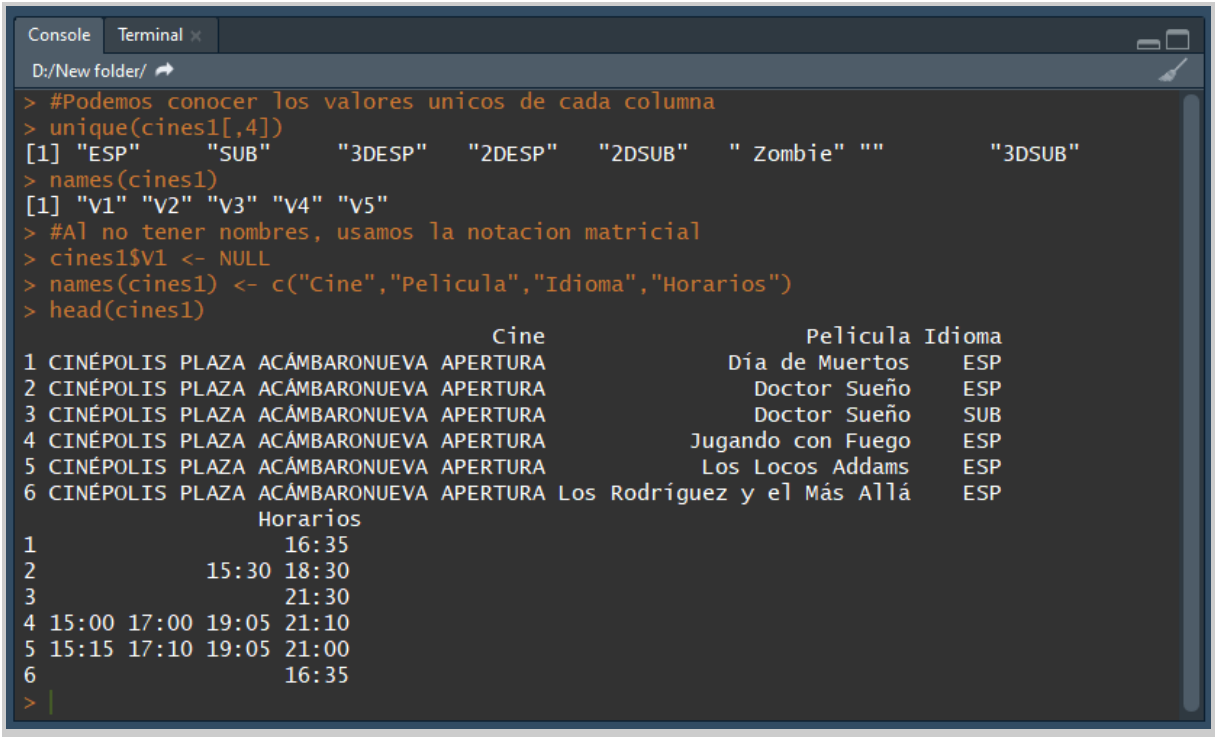

(Figura Caso 3.4) Observando el resultado que devuelve la función unique, es posible darse cuenta de que hay entradas con errores.

Particularmente hay espacios vacios y la palabra zombies: (Ver figura Caso 3.5)

```
#Eliminar vacios  y zombies
#Usando which, grepl y operadores condicionales
#grep para saber si hay "zombie" en la colimna
unique(grepl(pattern = unique(cines1[,3])[6],x =
cines1$Idioma))
```

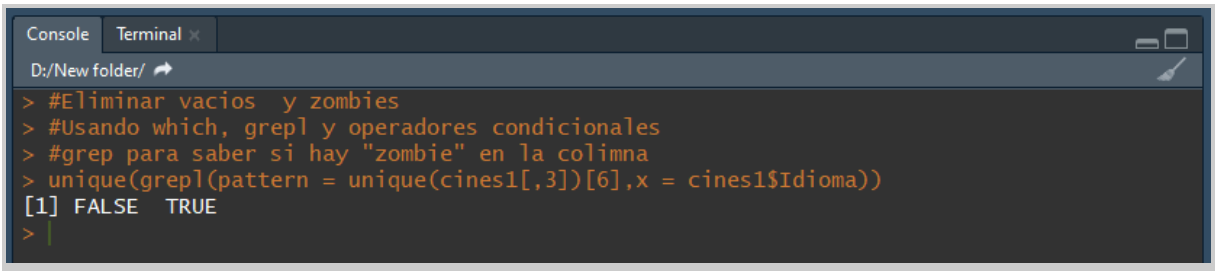

(Figura Caso 3.5) la evaluación de unique(cines1[,3])[6] es el carácter Zombie.

```
#Wich para conocer en que renglones hay TRUE
which(grepl(pattern = "Zombie", x = cines1$Idioma))
```

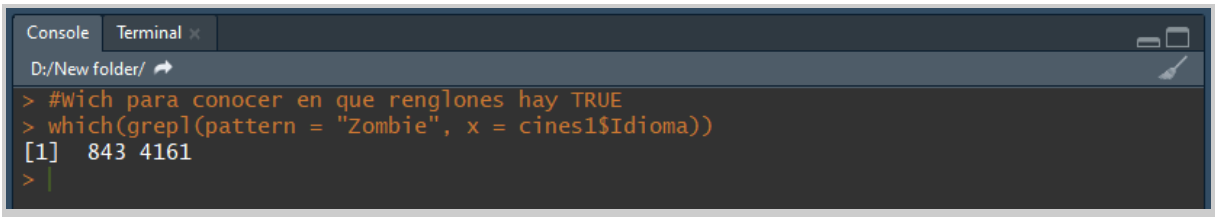

(Figura Caso 3.6) Hay 2 observaciones con la palabra zombie.

```
#comprobando que si digan zombie
cines1[c(843,4161),]
```

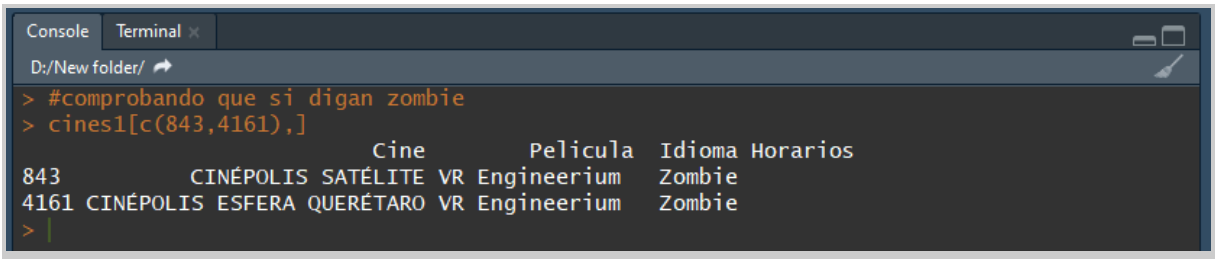

(Figura Caso 3.7) Efectivamente son observaciones erróneas.

```
#Función anidada que elimina función
cines1 <- cines1[-c(which(grepl(pattern =
unique(cines1$Idioma)[6], x = cines1$Idioma))),]
```

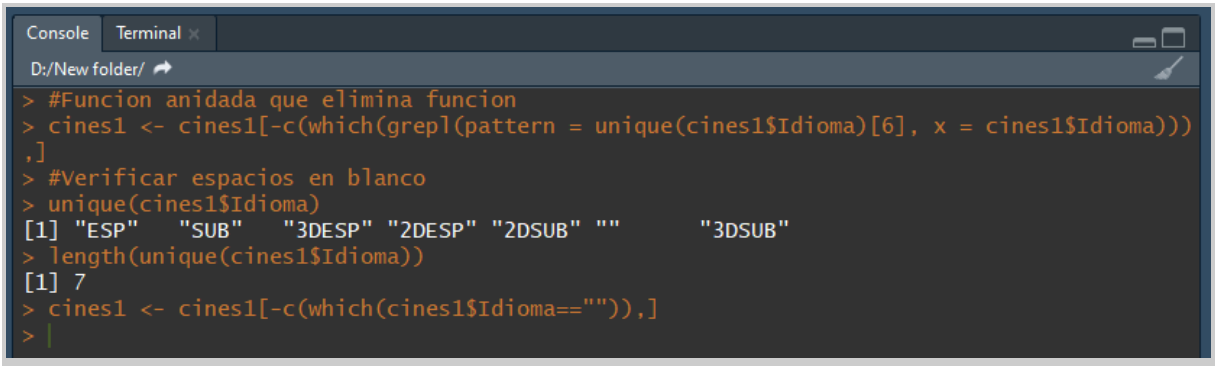

(Figura Caso 3.8) Se eliminaron las observaciones con error.

```
#Verificar espacios en blanco
unique(cines1$Idioma)
length(unique(cines1$Idioma))
cines1 <- cines1[-c(which(cines1$Idioma=="")),]
```

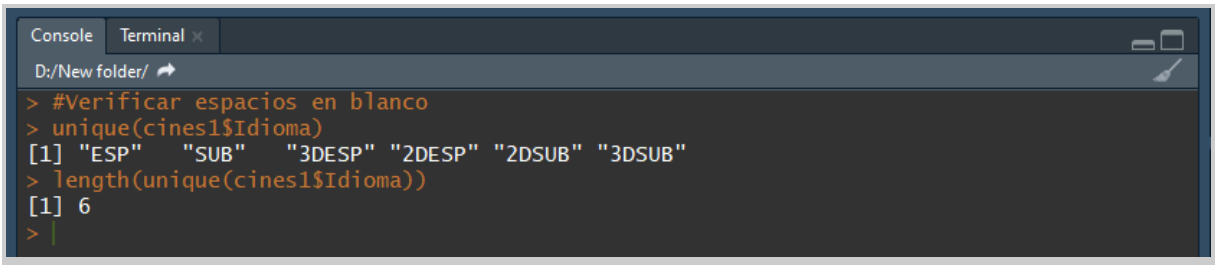

(Figura Caso 3.9) Se eliminaron las observaciones con espacios vacíos.

```
#separar horarios por columna con espacio
horarios <- strsplit(as.character(cines1$Horarios)," ")
horarios <- do.call(rbind, horarios)
cines1 <- data.frame(cines1, horarios)
```

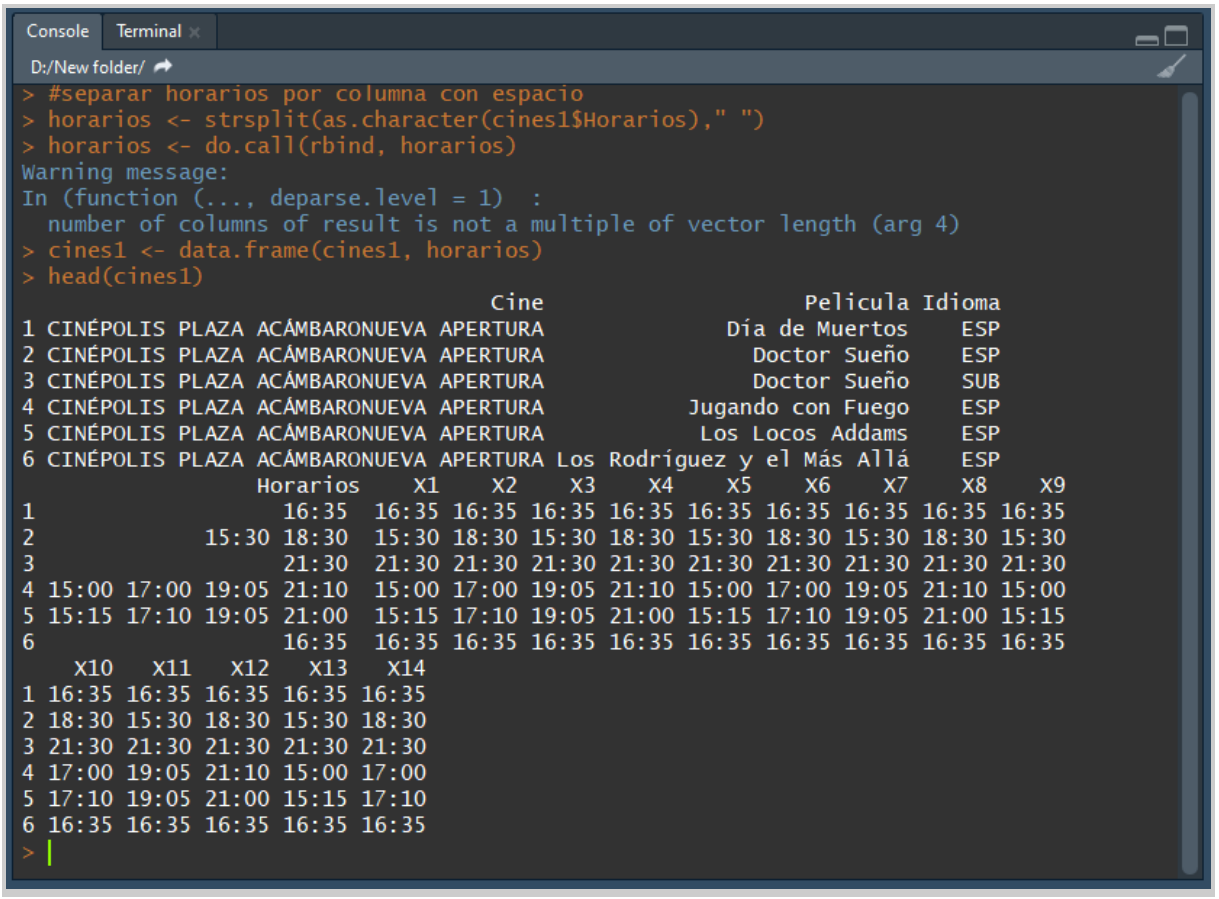

(Figura Caso 3.10) Se asigna un nombre a cada nueva variable.

Sin embargo podemos ver como se rellenan los espacios con el mismo horario, lo cuál estaría generando errores en la información, para corregir el error se tendría que volver a cargar el archivo, eliminar entradas con errores y separar los horarios por columna. Si se tienen escritas las instrucciones en la ventana del editor de forma ordenada, será muy fácil llegar a este punto. Con el siguiente comando, no se duplica información (Ver figura Caso 3.11)

```
library('plyr')
horarios <- strsplit(as.character(cines1$Horarios)," ")
horarios <- ldply(horarios, rbind)
cines1 <- data.frame(cines1, horarios)
```

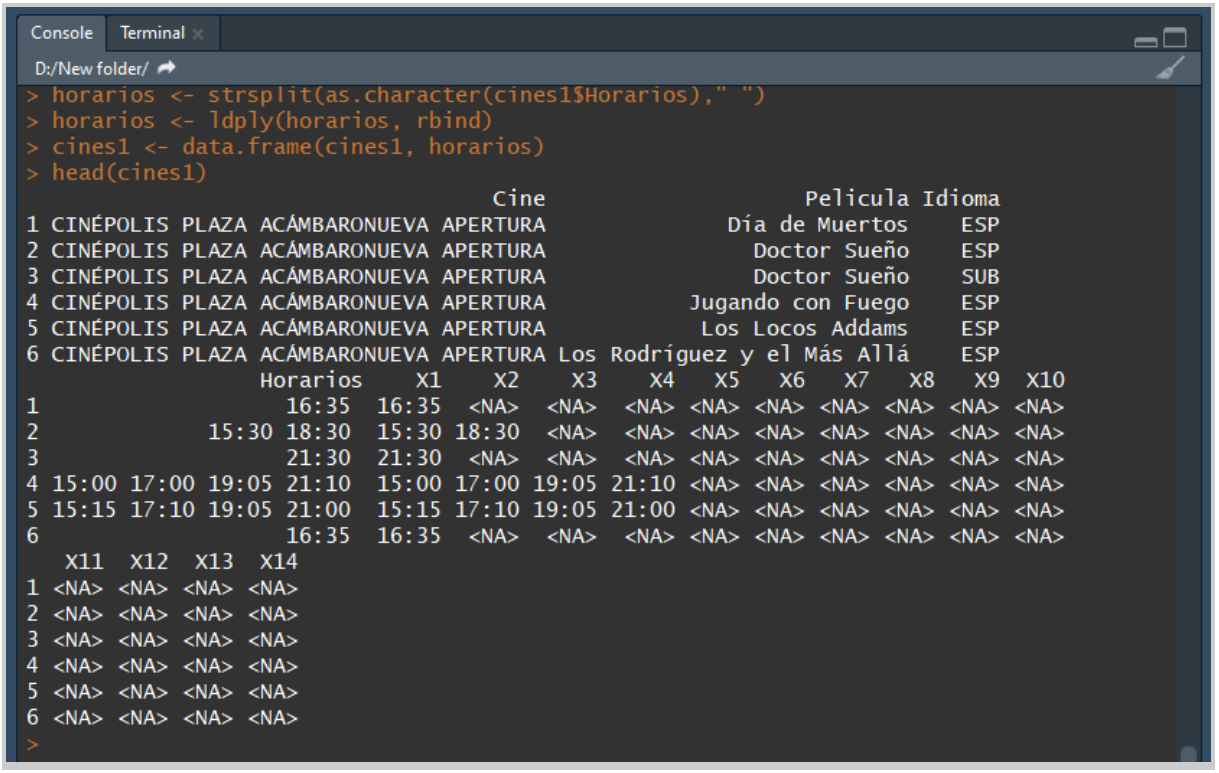

(Figura Caso 3.11) hay espacios vacios para películas con pocos horarios.

```
#Formato de horas
cines1[,5:18] <- lapply(cines1[,5:18], strptime,format =
"%H:%M")
head(cines1)
```

5.3 Preguntas de Negocio

De la misma manera que en el caso 1, se podrán correr los siguientes bloques de código para resolver preguntas de negocio alrededor de los horarios de las pelìculas en cines, se deja este ejercicio al lector

```
#total de horarios por formato
#cines con mas formatos de un tipo
#ordenar tablas con horario ascendente o descendente


library(dplyr)

horarios.pelicula <- (cines1 %>%
                        select(Pelicula,Horarios)%>%
                        group_by(Pelicula)%>%
                        summarise(cuenta =
n_distinct(Horarios))
)

head(horarios.pelicula)

horarios.Cine <- (cines1 %>%
                        select(Cine,Horarios)%>%
                        group_by(Cine)%>%
                        summarise(cuenta =
n_distinct(Horarios))
)
head(horarios.Cine)
```

6. Conclusiones

Como se pudo apreciar a lo largo del tutorial y durante las sesiones que fueron impartidas durante los semestres 2019-1 y 2019-2 de estas notas, la mejor manera de aprender un lenguaje de programación (en este caso R) y orientarlo hacia la inteligencia de negocios, es tomar un problema real y resolverlo. Distintos problemas van a encontrarse con grados de madurez de datos diferentes, es decir, habrá situaciones en donde los datos se encuentren “limpios” en una base de datos en donde la tarea será conectarse a dicha base para empezar a trabajar con la información; en otros casos, los datos se podrán encontrar dentro de carpetas con varios archivos históricos en formato excel en donde la tarea será hacer una curaduría de los datos mediante la automatización del proceso de leer de los archivos, extraer los datos necesarios y validarlos;o bien, los datos tendrán que buscarse o empezar a generarse desde cero.

Independientemente de la madurez o accesibilidad en la que se encuentren los datos, a la persona que busque implementar una inteligencia de negocio a partir del análisis de datos, le va a corresponder realizar una correcta abstracción del problema de negocio, interpretar los datos, plantear un modelo, visualizar la información, y generar hallazgos de valor para el negocio a partir del análisis que se realice y así poder comunicar de manera efectiva el diagnóstico de los siguientes pasos a tomar al resto del equipo y miembros de la organización.

Es posible que este tutorial tenga ciertas carencias en cuanto a profundidad de los temas, debido a que se enfoca en la resolución de problemas específicos y no abarca todas las funcionalidades del lenguaje de programación. Sin embargo, es importante tener en cuenta que este tutorial es solo una introducción al tema y puede ser utilizado como un punto de partida para profundizar en temas específicos de acuerdo a las necesidades del usuario. Además, el tutorial proporciona una buena comprensión de los conceptos clave necesarios para comenzar a aplicar el lenguaje de programación R en la inteligencia de negocios, como la limpieza y manipulación de datos, la visualización de información y la interpretación de resultados. Estos conceptos son fundamentales para cualquier proyecto de inteligencia de negocios y proporcionan una base sólida para profundizar en temas específicos.

En resumen, el tutorial del Lenguaje de Programación R orientado a la inteligencia de negocios proporciona herramientas valiosas para aquellos interesados en aplicar análisis de datos a problemas de negocio. A través de la resolución de problemas reales, el tutorial enfatiza la importancia de la abstracción, interpretación y visualización de los datos para obtener hallazgos valiosos para la organización. A pesar de que los datos pueden encontrarse en diferentes estados de madurez, es crucial que el analista sea capaz de manipularlos y utilizarlos para comunicar de manera efectiva el diagnóstico de los siguientes pasos a tomar al resto del equipo y miembros de la organización. En definitiva, el tutorial ofrece una guía práctica para aquellos que buscan aplicar el Lenguaje de Programación R a la inteligencia de negocios.

7. Referencias de Fuentes Consultadas

1.-*Online Courses - Learn Anything, On Your Schedule | Udemy*. (n.d.). Udemy. https://www.udemy.com/
Analytics Vidhya. (n.d.). Analytics Vidhya. https://courses.analyticsvidhya.com/
Learn R | Codecademy. (n.d.). Codecademy. https://www.codecademy.com/learn/learn-r

2.- *Stack Overflow - Where Developers Learn, Share, & Build Careers*. (n.d.). Stack Overflow. https://stackoverflow.com/

3.-*R: What is R?* (n.d.). R: What Is R? https://www.r-project.org/about.html

4.-*Simply Statistics: Teaching R to New Users - From tapply to the Tidyverse*. (2018, July 12). Simply Statistics. https://simplystatistics.org/posts/2018-07-12-use-r-keynote-2018/

5.-*Posit*. (n.d.). Posit. https://www.posit.co/

6.- *The Comprehensive R Archive Network*. (n.d.). The Comprehensive R Archive Network. https://cran.r-project.org/

7.-G. (n.d.). *Build software better, together*. GitHub. https://github.com

8.-*Tidyverse*. (n.d.). Tidyverse. https://www.tidyverse.org/

9.-Grolemund, G., & Wickham, H. (2017). *R for Data Science*. O'Reilly Media.

10.- *Solutions - Setting up ODBC Drivers*. (n.d.). Solutions - Setting up ODBC Drivers. https://db.rstudio.com/best-practices/drivers/

11.- *seananderson.ca*. (n.d.). An Introduction to Reshape2 - Reshaping Data Easily With the Reshape2 R Package. - seananderson.ca. https://seananderson.ca/2013/10/19/reshape/

12.- *Converting excel DateTime serial number to R DateTime*. (2013, October 4). Stack Overflow. https://stackoverflow.com/questions/19172632/converting-excel-datetime-serial-number-to-r-datetime

13.- Wickham, H. (n.d.). *4 Pipes | The tidyverse style guide*. 4 Pipes | the Tidyverse Style Guide. https://style.tidyverse.org/pipes.html

14.-Zorrilla, J. P. (2017, December 26). *¿Rentar es tirar dinero a la basura?* Forbes. Retrieved December 5, 2019, from https://www.forbes.com.mx/rentar-es-tirar-dinero-a-la-basura/

15.-*How do I strip dollar signs ($) from data/ escape special characters in R?* (2011, July 10). Stack Overflow. https://stackoverflow.com/questions/6639713/how-do-i-strip-dollar-signs-from-data-escape-special-characters-in-r

8. Bibliografía

-Grolemund, G., & Wickham, H. (2017). *R for Data Science*. O'Reilly Media.

-The R Foundation (n.d.). *The R Project for Statistical Computing*. R-Project. Retrieved December 5, 2019, from https://www.r-project.org/

-Posit Software (n.d.). *The open source data science company*. 2023 Posit Software, PBC Formerly RStudio, PBC. Retrieved December 5, 2019, from https://www.rstudio.com/

-Srivastava, T. (2015, April 26). *Comprehensive guide for Data Exploration in R*. Analytics Vidhya. Retrieved December 5, 2019, from https://www.analyticsvidhya.com/blog/2015/04/comprehensive-guide-data-exploration-r/

-Chou, L. (2019, November 7). *How Can Beginners Create a Great Dashboard?* Towards Data Science. Retrieved December 5, 2019, from https://towardsdatascience.com/how-can-beginners-create-a-great-dashboard-cf48c0f68cd5

-Kristiansen, S. L. (2018, March 16). *Create PDF reports using R, R Markdown, LaTeX and knitr (on macOS High Sierra)*. Medium. Retrieved December 5, 2019, from https://medium.com/@sorenlind/create-pdf-reports-using-r-r-markdown-latex-and-knitr-on-macos-high-sierra-e7b5705c9fd

-Posit Software (n.d.). *Posit Cheatsheets*. 2023 Posit Software, PBC Formerly RStudio, PBC. Retrieved December 5, 2019, from https://www.rstudio.com/resources/cheatsheets/

-Karn, U. (n.d.). *R Data Science Tutorials*. Github. Retrieved December 5, 2019, from https://github.com/ujjwalkarn/DataScienceR