

Estructuras de datos

Software Estadístico

Dra. Eva Romero Ramos

Dpto. Estadística e Investigación Operativa

- Ya conocemos los tipos básicos de datos, ahora veremos algunas estructuras en las que se pueden almacenar los datos.
- Las estructuras de datos en R son tipos de objetos que nos permitirán almacenar y operar con los datos.
- Las estructuras de datos pueden contener datos el mismo tipo (**homogéneas**) o de distinto tipo (**heterogéneas**).
- Conoceremos en este tema las siguientes estructuras de datos: Vector, Matriz, Array, Lista y Data Frame.

- Un vector es una estructura homogénea de una dimensión, cuyo tipo de datos hace referencia al tipo de los datos que contiene.
- Podemos crear un vector usando la función `c()`.

Ejemplo.- `Vector <- c(1,2,5,7,9)`

`CharVector <- c("Luis", "Lola", "Marcos")`

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

- Para ver el tamaño de un vector podemos usar la función `length()`.

Ejemplo.- `length(Vector)`

- Podemos crear vectores formados por secuencias numéricas.

Ejemplo.- `v3 <- c(1:10)`

- También se pueden crear vectores por secuencias numéricas con la función `seq()`.

Ejemplo.- `v4 <- seq(0, 100, by = 5)`

- Se pueden realizar operaciones aritméticas entre vectores.

Ejemplo.- `v3 + v4`

- Se pueden agregar elementos nuevos a un vector mediante:

`v3 <- c(v3,15)`

- Se pueden combinar vectores mediante:

`c(v3,v4)`

- Accederemos a los elementos del vector, indicando el índice del elemento u elementos que nos interesen entre corchetes.

`v3[2]`

- Podemos crear una variable tipo **factor** a partir de un vector.

Ejemplo.-

```
colores <- c('azul', 'verde', 'verde', 'rojo', 'azul', 'verde',  
'rojo')
```

```
colores; class(colores)
```

```
coloresfactor <- as.factor(colores)
```

```
coloresfactor; class(coloresfactor)
```

- Una variable tipo factor, es una variable que toma un pequeño rango de valores alfanuméricos para cada item.

- 1 Los **arrays** y las **matrices** son estructuras homogéneas de más de una dimensión.
- 2 La principal diferencia entre ambos es que los arrays pueden tener cualquier número de dimensiones (incluido una) y las matrices tienen siempre dos dimensiones.
- 3 Para crear un **array** usaremos la función **array()**:
Ejemplo.- `A1 <- array(0, dim = c(2, 3, 4))`
- 4 Para crear una matrix usaremos la función **matrix()**:
Ejemplo.- `Mat1 <- matrix(0, nrow = 3, ncol = 4)`
- 5 Otra diferencia importante es que **arrays** y **matrices** tienen funciones diferentes.

- El uso de arrays no es tan común como el uso de matrices así nos centraremos un poco más en estas.
- Otra forma de crear matrices es haciendo uso de la funciones `rbind()` y `cbind()`.

- **`rbind()`** une filas.

Ejemplo.- `Mat4 <- rbind(2,3,5, NA)`

- **`cbind()`** une columnas.

Ejemplo.- `Mat7 <- cbind(1:3, c(2,7,NA), c(9,6,3))`

- Podemos usar el comando **`dim()`** para conocer las dimesiones de una matriz.

Ejemplo.- `dim(Mat7)`

- Accederemos a los elementos de una matriz mediante índices, indicando las posiciones del valor que nos interese entre corchetes.

Ejemplo.- `Mat7[2,3]`

`Mat7[2,]`

`Mat7[,3]`

- Al igual que en el caso de los vectores, se pueden utilizar operadores aritméticos entre matrices.

- Los **Data Frames** son estructuras de datos bidimensionales y heterogéneas.
- Es la estructura más utilizada en análisis de datos.
- Cada columna de un data frame se refiere a una variable o atributo y cada fila corresponde con una observación.
- Para crear un data frame se utiliza el comando **data.frame()**.
Ejemplo.- `df_personas <- data.frame(Nombre = c('Juan', 'María', 'Luis'), Edad = c(25,23,19), Genero = c('M','F','M'))`

- Podemos usar el comando `dim()` para ver la dimensión del data frame.

Ejemplo.- `dim(df_personas)`

- El comando `length()` nos indica el número de columnas del data frame.
- `names()` nos da el nombre de la columnas y también nos permite cambiarlo si lo usamos en una asignación.

Ejemplo.- `names(df_personas) <- c('Name', 'Age', 'Gender')`

- La función `as.data.frame()` permite convertir una matriz en un dataframe.
- Como un data frame está compuesto por vectores les podremos aplicar los mismos operadores.

- Podemos acceder a los elementos de un data frame mediante los nombres de las variables y mediante índices.
- Si lo hacemos mediante los nombres de las variables debemos escribir el nombre de data frame seguido de \$ y seguido del nombre de la columna a la que queremos acceder.

Ejemplo.- `df_personas$Age`

- Esta acción nos permite acceder a la columna completa del data frame.
- Si queremos acceder a un dato, es decir a una celda, debemos usar índices o combinar los nombres con índices:

Ejemplo.- `df_personas$Age[2]`
`df_personas[2,2]`

Listas

- Las listas son estructuras de datos unidimensionales y heterogéneas.
- Las listas pueden incluir cualquier tipo de datos, incluidos vectores, matrices e incluso dataframes.
- Para crear listas usaremos el comando `list()`.
Ejemplo.- `lista <- list(nombre = 'Juan', edad = 21, calificaciones = c(9.5, 8.7, 7.8), aprobado = TRUE)`
- Observamos en el ejemplo que cada elemento de la lista puede tener un nombre.
- Accederemos a los elementos de la lista con el nombre de la lista seguido de `$`.
Ejemplo.- `lista$aprobado`
- Podemos obtener el tamaño de la lista con la función `length()`.
- No se pueden aplicar operadores aritméticos a los elementos de una lista.

- Ya hemos visto que en ocasiones nos interesa cambiar el tipo de datos para poder operar con los datos con las funciones que nos interesen.
- Para coercionar los datos tenemos las funciones del tipo **as()**.
- En el caso de los datos estudiados las funciones de coerción son:
 - **as.vector()** → Coerciona a vector las matrices.
 - **as.matrix()** → Coerciona a matrices, vectores y dataframes.
 - **as.data.frame()** → Coerciona a dataframes los vectores y matrices.
 - **as.list()** → Coerciona a lista los vectores y dataframes.