



Wordclouds en R

Por: Víctor Manuel Sarmiento García  y Nikoll Meneses Zambrano 
Diseño por: Laura Barrera Valdés

Índice

00	Introducción	01
01	Limpieza	01
02	Procesamiento	01
03	Visualización	02

Introducción

Las nubes de palabras (también conocidas como nubes de texto o nubes de etiquetas) funcionan de forma sencilla: cuanto más aparece una palabra en una fuente de datos de texto (como un discurso, una entrada de un blog o una base de datos), más grande y destacada se muestra en la nube de palabras.

NOTA: si usted ya tiene una base de datos con cada palabra y su respectiva frecuencia de aparición, pase a la sección 3h. En caso contrario, continúe a la sección 1 para limpiar el texto. En este caso será usado como ejemplo el discurso del Expresidente Colombiano Juan Manuel Santos en la firma del acuerdo de paz con la extinta guerrilla Farc-EP. Se recomienda acceder este [link](#) para descargar los archivos necesarios para seguir esta guía.

01 Limpieza

Inicialmente, se carga el texto.

```
text <- readLines(con = "Santos.txt", encoding = "UTF-8")
```

A continuación, se usa el paquete tm para crear un objeto Corpus que puede ser fácilmente manipulado con algunas técnicas de minería de textos.

```
library(tm)
```

```
text1 <- Corpus(x = VectorSource(x = text))
```

Luego, se convierten todas las palabras del discurso a minúsculas,

```
text1 <- tm_map(x = text1, FUN = tolower)
```

y se eliminan los espacios en blanco,

```
text1 <- tm_map(x = text1, FUN = stripWhitespace)
```

los signos de puntuación,

```
text1 <- tm_map(x = text1, FUN = removePunctuation)
```

los números,

```
text1 <- tm_map(x = text1, FUN = removeNumbers)
```

y las palabras sin significado como artículos, pronombres, preposiciones, etc.

```
text1 <- tm_map(text1, removeWords, stopwords("spanish"))
```

Hasta ahora ya se ha creado el objeto Corpus y está ajustado. Ahora se procesarán los datos de tal forma que se pueda crear una base de datos en donde se encuentre cada palabra junto a su respectiva frecuencia de aparición.

02 Procesamiento

Primero, se debe convertir el objeto Corpus a una matriz en la que sus filas representen las oraciones de los datos que deben analizarse, mientras que las columnas representen cada palabra existente en el texto.

```
text_matrix <- TermDocumentMatrix(x = text1)
```

Después, se transforma este en una matriz más sencilla.

```
text_matrix <- as.matrix(text_matrix)
```

Así, se suma la cantidad de veces que aparece cada palabra, se organizan de mayor a menor frecuencia de aparición,

```
text_data <- sort(rowSums(text_matrix), decreasing = TRUE)
```

y se crea un data frame. Una columna contiene las palabras, y la otra su respectiva frecuencia absoluta.

```
text_data1 <- data.frame(word = names(text_data),freq=text_data)
```

03 Visualización

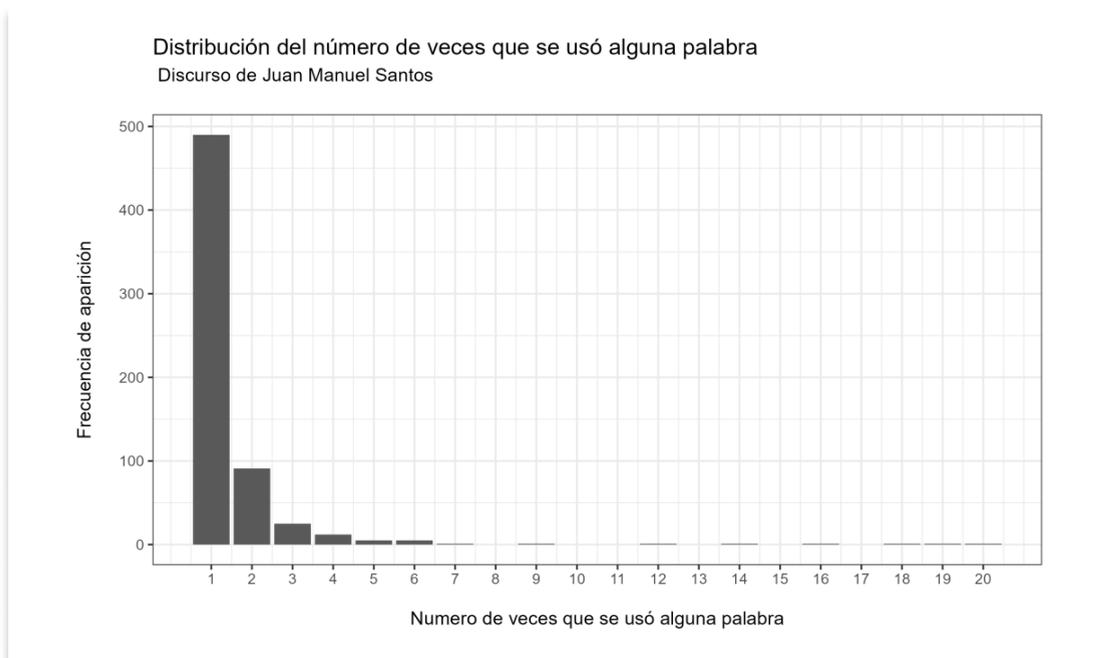
03.1. Graficos Tradicionales

La forma más sencilla de visualizar la frecuencia de aparición de estas palabras es usando graficos tradicionales con la libreria ggplot2.

El primer grafico, por ejemplo, muestra la frecuencia de aparición del numero de veces que aparece una palabra. Con esto es posible ver si hay unas cuantas palabras que se usan muchas veces, o bien, si hay muchas palabras que se usan pocas veces.

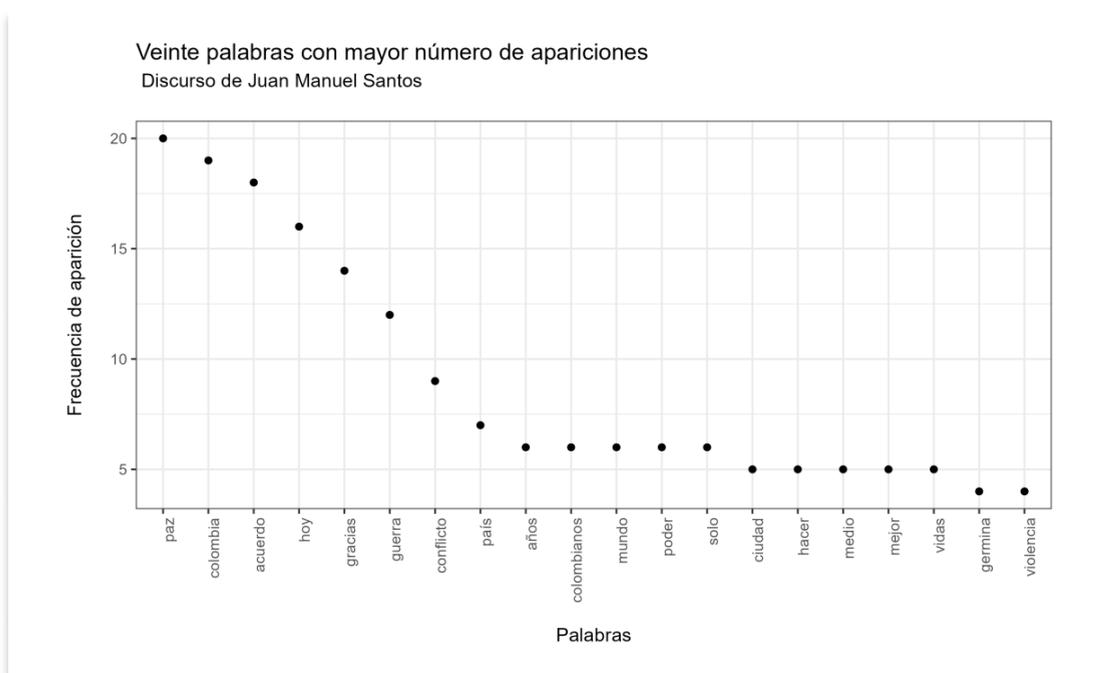
```
library(ggplot2)
```

```
ggplot(data = text_data, aes(x= freq)) + geom_bar()+ labs(title = "Distribución de la frecuencia de aparición de palabras",subtitle = "Discurso de Juan Manuel Santos", x=" \nNumero de palabras", y="Frecuencia de aparición\n")+ scale_x_continuous(labels = c(1:20), breaks = c(1:20))+ theme_bw()
```



Para saber cuales son esas palabras, y qué tanto aparecen en el discurso, se debe analizar el segundo grafico.

```
ggplot(data = text_data[1:20, ], aes(x= reorder(word, -freq), y = freq )) + geom_point() + labs(title = "Veinte palabras con mayor número de apariciones",subtitle = " Discurso de Juan Manuel Santos", x=" \nPalabras",y="Frecuencia de aparición\n") + theme_bw()+ theme(axis.text.x = element_text(angle = 90, hjust = 1))
```



Sin embargo, ninguno de los dos graficos son muy intuitivos ni llamativos. Es justo por esta razón que se prefiere usar las nubes de palabras cuando se analizan textos, discursos, etc.

