Herramientas del BIG DATA y analytics

Empezando a visualizar datos con R y *ggplot2*

Autores:
Julio César Alonso
Maria Fernanda Largo

Editorial Universidad Icesi
UNIVERSIDAD ICESI

Empezando a visualizar datos con R y ggplot2

Julio César Alonso[1] Maria Fernanda Largo[2]

8 de septiembre de 2022

[1]CIENFI - Universidad Icesi, jcalonso@icesi.edu.co
[2]CIENFI - Universidad Icesi, mflargo@icesi.edu.co

Julio César Alonso C. y Maria Fernanda Largo L.

Colección «Herramientas del Big Data y Analytics», vol. 3

Cali. Universidad Icesi, 2022.

94 páginas.

Incluye referencias bibliográficas.

ISBN: 978-628-7538-85-6 (eBook).

DOI: https://doi.org/10.18046/EUI/bda.h.3

Palabras Clave: 1. R | 2. Analítica | 3. ggplot | 5. Visualizaciones | 5. Big Data Analytics

Clasificación Dewey: 545 ddc 21

CIENFI - Centro de Investigación en Economía y Finanzas

www.icesi.edu.co/centros-academicos/cienfi

Rector: Esteban Piedrahita Uribe

Secretaria General: María Cristina Navia Klemperer

Director Académico: José Hernando Bahamón

Coordinador editorial: Adolfo A. Abadía

Corrección de estilo: Claudia L. González G.

Diseño de portada: Sandra Moreno

Fotos tomadas por: Julio César Alonso

Editorial Universidad Icesi

Calle 18 No. 122-135 (Pance), Cali – Colombia

Teléfono: +57 (2) 555 2334 | E-mail: editorial@icesi.edu.co

http://www.icesi.edu.co/editorial

Publicado en Colombia – *Published in Colombia*

La publicación de este libro se aprobó luego de superar un proceso de evaluación doble ciego.

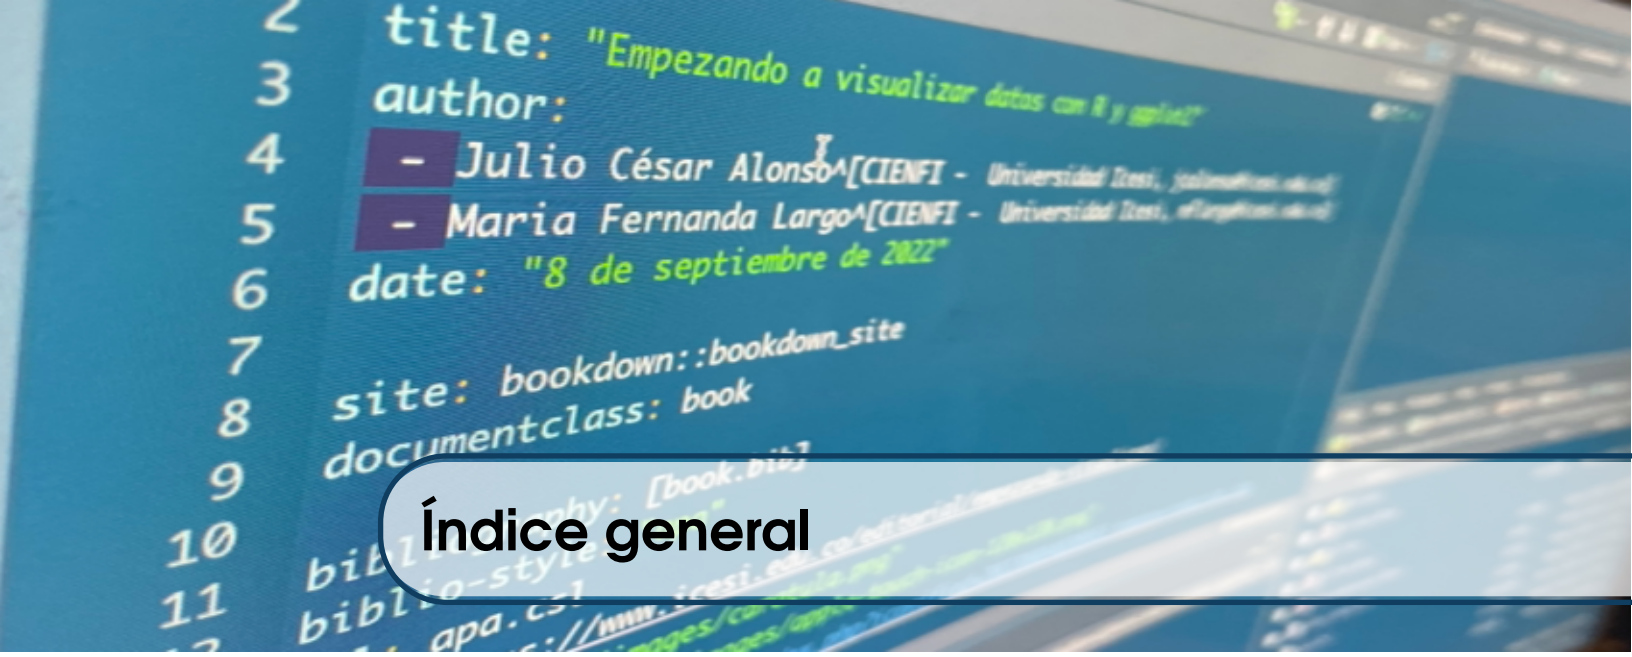

Índice general

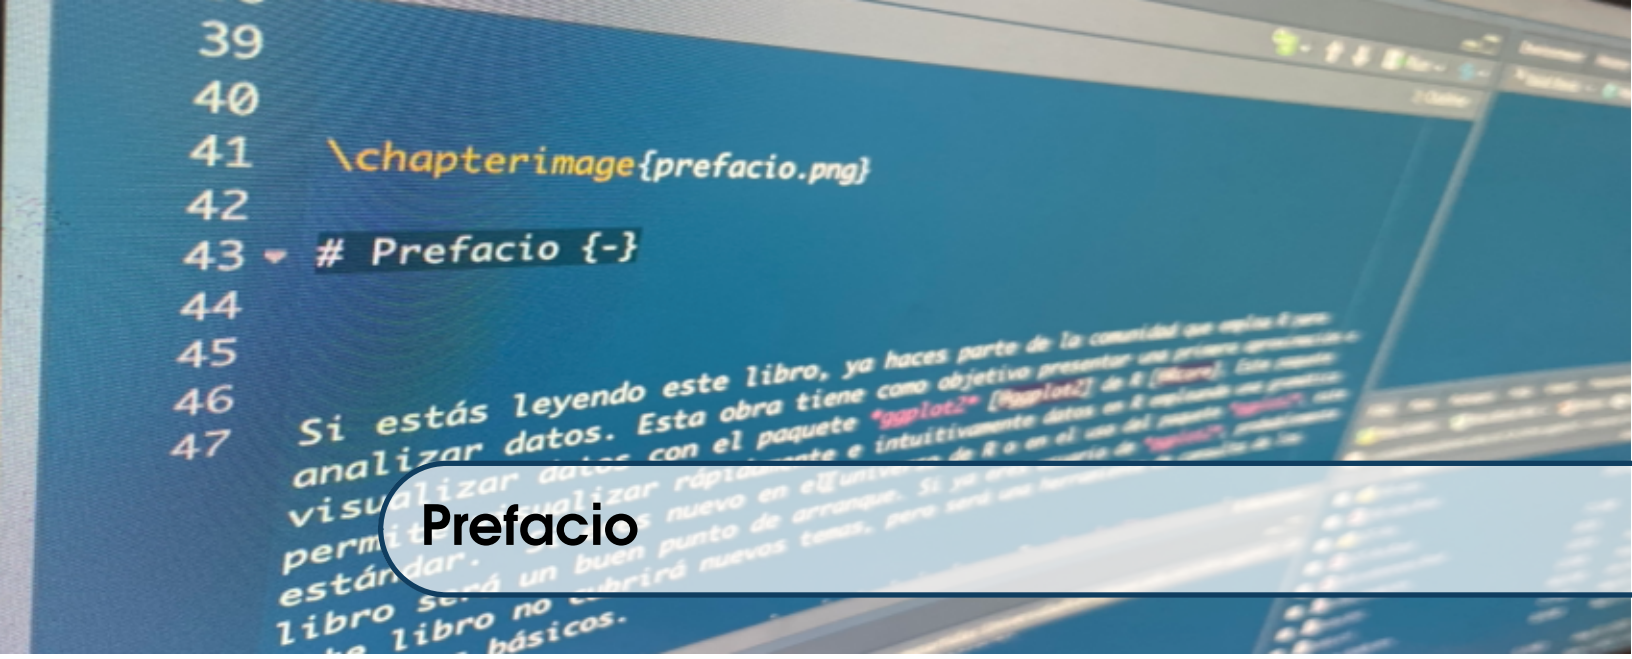

Prefacio

Si estás leyendo este libro, ya haces parte de la comunidad que emplea R para analizar datos. Esta obra tiene como objetivo presentar una primera aproximación a visualizar datos con el paquete *ggplot2* (Wickham, 2016) de R (R Core Team, 2018). Este paquete permite visualizar rápidamente e intuitivamente datos en R empleando una gramática estándar. Si eres nuevo en el universo de R o en el uso del paquete *ggplot2*, este libro será un buen punto de arranque. Si ya eres usuario de *ggplot2*, probablemente este libro no cubrirá nuevos temas, pero será una herramienta de consulta de los conceptos básicos.

Aquí se recoge nuestra experiencia trabajando con R y *ggplot2* para resolver problemas con datos desde el CIENFI (Centro de Investigación en Economía y Finanzas) de la Universidad Icesi. En el CIENFI, empleamos R para la transformación de datos en conclusiones que faciliten la toma de decisiones en organizaciones privadas y públicas. Toda esta experiencia la queremos plasmar en esta obra para asegurar que nuevas generaciones de profesionales continúen fortaleciendo la comunidad de R alrededor del mundo.

Este libro también refleja la evolución del paquete y conocimiento que hemos recogido en el CIENFI desde la primera guía introductoria al paquete publicada en 2012 (Alonso y González, 2012). Los comentarios de sus lectores y estudiantes nos han motivado para escribir este libro.

Este es el tercero de una serie de libros introductorios al uso de R. El primer libro (Alonso y Ocampo, 2022) presenta una breve introducción para iniciar a usar R. En él se enseña cómo instalar R, la interfaz RStudio y paquetes, cómo cargar diferentes bases de datos y cómo realizar operaciones aritméticas y lógicas con objetos. También se discuten las clases esenciales de objetos sencillos y compuestos. No dudes en consultar ese primer libro si aún no has iniciado tu camino por el universo de R, lo

puedes encontrar en: https://www.icesi.edu.co/editorial/empezando-usar/ .

El segundo libro de la serie (Alonso, 2022) corresponde a una introducción al paquete *dplyr* (Wickham et al., 2021), el cual permite manipular objetos que contengan datos. En esa obra mostramos cómo filtrar observaciones, crear nuevas variables y combinar objetos con datos. Es recomendable tener un conocimiento de ese paquete antes de leer esta obra. Consulta ese segundo libro si aún no has tenido alguna experiencia manipulando objetos con datos con *dplyr*. Lo puedes encontrar en el siguiente enlace: http://www.icesi.edu.co/editorial/empezando-transformar/ .

En este tercer libro de la serie nos concetraremos en cómo visualizar datos empleando el paquete *ggplot2*. En el flujo de trabajo que nos lleva de los datos a la toma de decisiones, las visualizaciones son importantes en la exploración de los datos y en la comunicación de los resultados. Es ahí dónde nos centraremos en este libro en escoger la mejor visualización de los datos que tengamos.

¡Esperamos encuentres esta obra útil y la compartas con otros futuros usuarios interesados! Si tienes alguna sugerencia del libro o corrección, no dudes en escribirme. Esta es una obra en constante construcción.

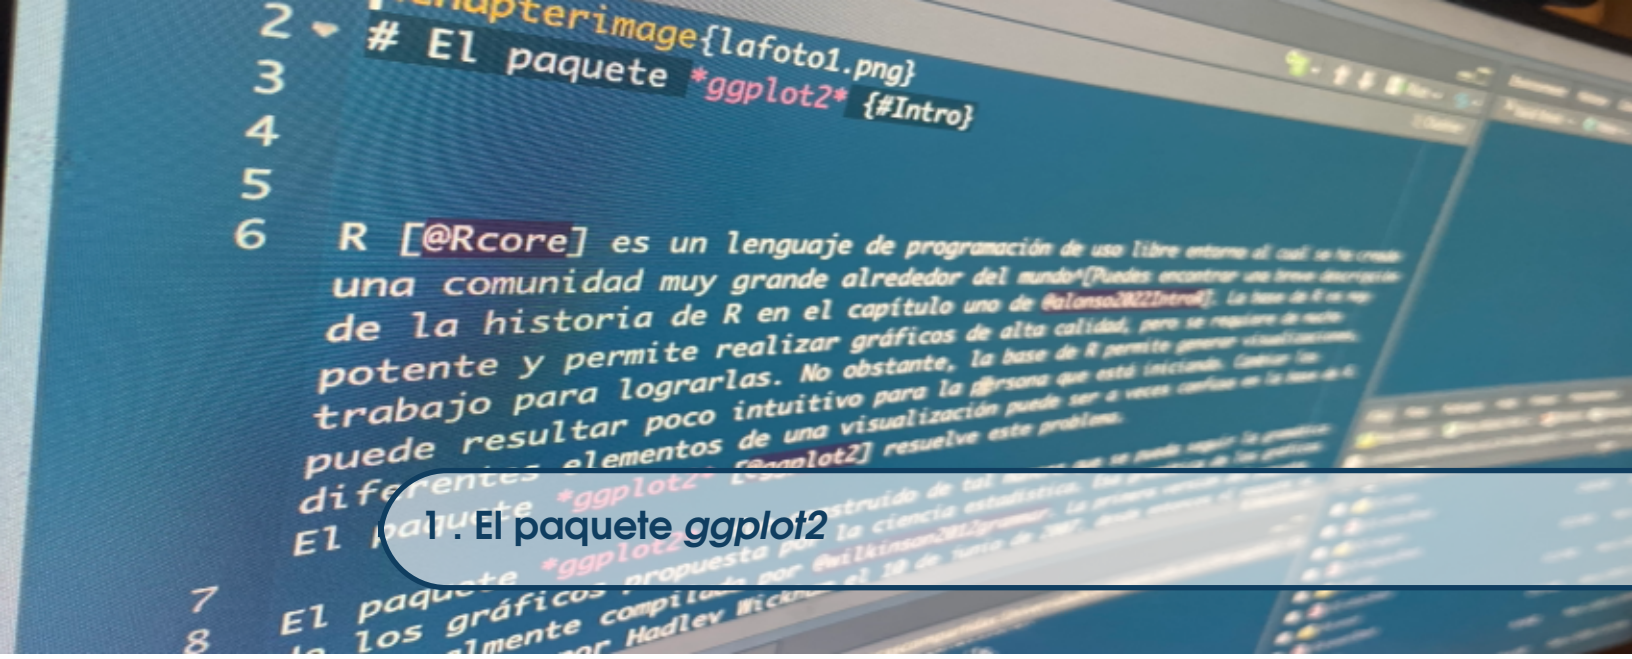

1 El paquete *ggplot2*

R (R Core Team, 2018) es un lenguaje de programación de uso libre entorno al cual se ha creado una comunidad muy grande alrededor del mundo[1]. La base de R es muy potente y permite realizar gráficos de alta calidad, pero se requiere de mucho trabajo para lograrlas. No obstante, la base de R permite generar visualizaciones, puede resultar poco intuitivo para la persona que está iniciando. Cambiar los diferentes elementos de una visualización puede ser a veces confuso en la base de R. El paquete *ggplot2* (Wickham, 2016) resuelve este problema.

El paquete *ggplot2* fue construido de tal manera que se pueda seguir la gramática de los gráficos propuesta por la ciencia estadística. Esa gramática de los gráficos fue finalmente compilada por Wilkinson (2012). La primera versión del paquete fue liberada por Hadley Wickham el 10 de junio de 2007, desde entonces el paquete se ha enriquecido con diferentes elementos. En los últimos años *ggplot2* se ha convertido en el paquete de creación de visualizaciones más popular en el universo R por permitir de manera sencilla obtener gráficos de alta calidad. Por ejemplo, en las Figuras 1.1, 1.2 y 1.3 vemos unas visualizaciones creadas con *ggplot2* empleando un par de líneas.

La Figura 1.1 presenta un diagrama de cajas (o también conocido como *Boxplot*) que además incluye cada una de las observaciones por grupo; en el Capítulo 3 explicaremos cómo interpretar y construir estas visualizaciones.

[1] Puedes encontrar una breve descripción de la historia de R en el capítulo uno de Alonso y Ocampo (2022)

Figura 1.1. Distribución del PIB percápita por continente (2007)

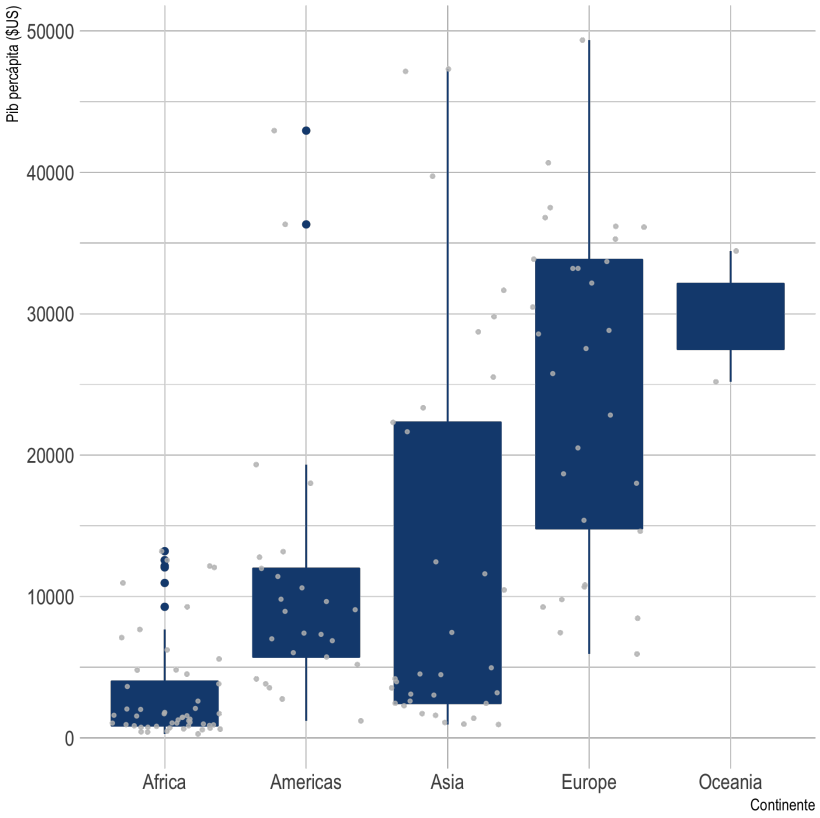

Fuente: Datos de gapminder y cálculos propios.

La Figura 1.2 presenta un gráfico de barras tradicional que aprenderemos a construir en el Capítulo 3. Ese gráfico lo hemos "embellecido" empleando unos trucos que estudiaremos en el Capítulo 6.

Figura 1.2. PIB percápita de los países del continente Americano (2007)

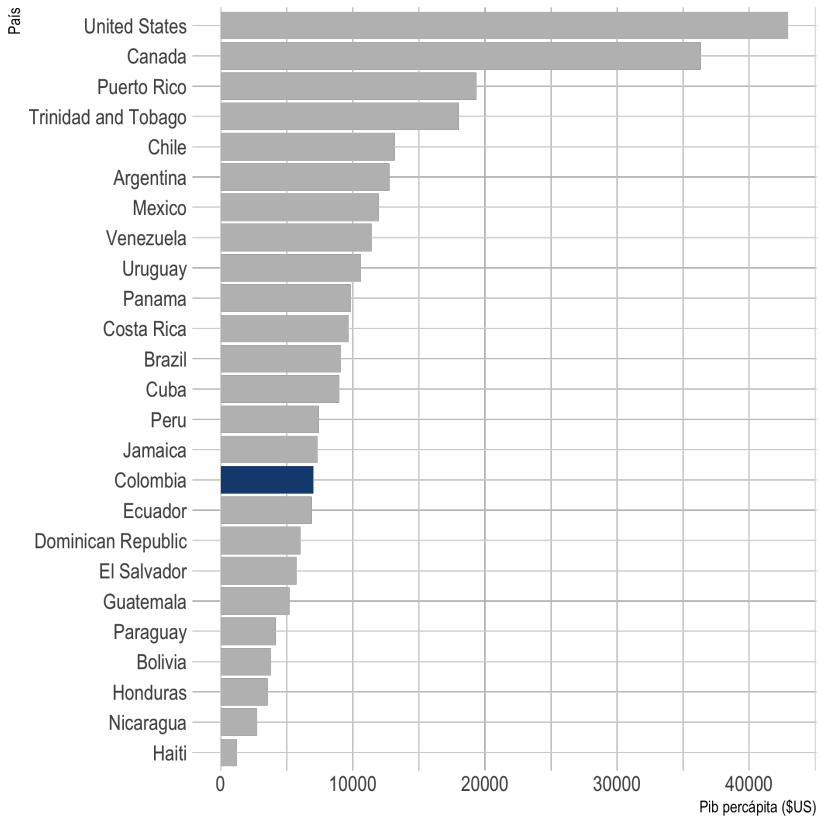

Fuente: Datos de gapminder y cálculos propios.

La Figura 1.3 presenta un gráfico de líneas con una anotación que permite resaltar uno de los casos. El gráfico de líneas lo estudiaremos en el Capítulo 4 y en el Capítulo 6 veremos como hacer las anotaciones y resaltar una sola línea.

Figura 1.3. Evolución del PIB percápita de Colombia y otros países de las Américas

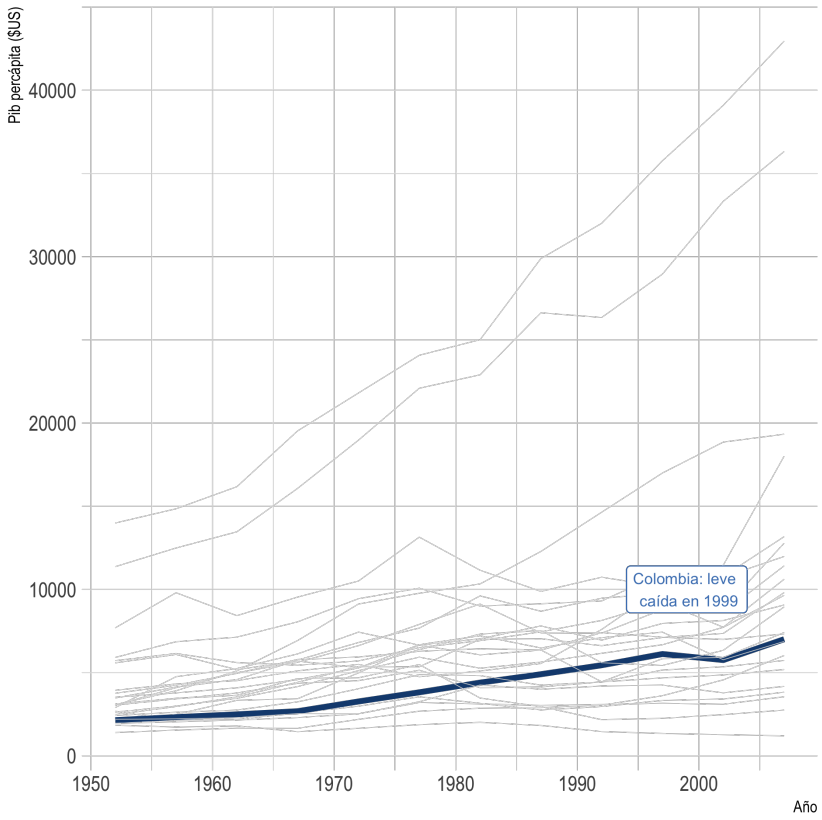

Fuente: Datos de gapminder y cálculos propios.

Es más, también existen numerosos paquetes que emplean la lógica de *ggplot2* para ampliar sus funcionalidades, permitiendo nuevos tipos de visualizaciones. Por ejemplo, el paquete *treemapify* (Wilkins, 2019) con el que se construyó el *treemap*, reportado en la Figura 1.4. Otro ejemplo, se presenta en al Figura 1.5 que fue creada con los paquetes *colmaps* (Moreno, 2015a) y *homicidios* (Moreno, 2015b) . En el Capítulo 2 estudiaremos la lógica detrás de la gramática de las visualizaciones que emplea *ggplot2* y que podrás aplicar para otros paquetes como *treemapify* y *colmaps*.

Figura 1.4. Composición de la población mundial y esperanza de vida al nacer por país (2007)

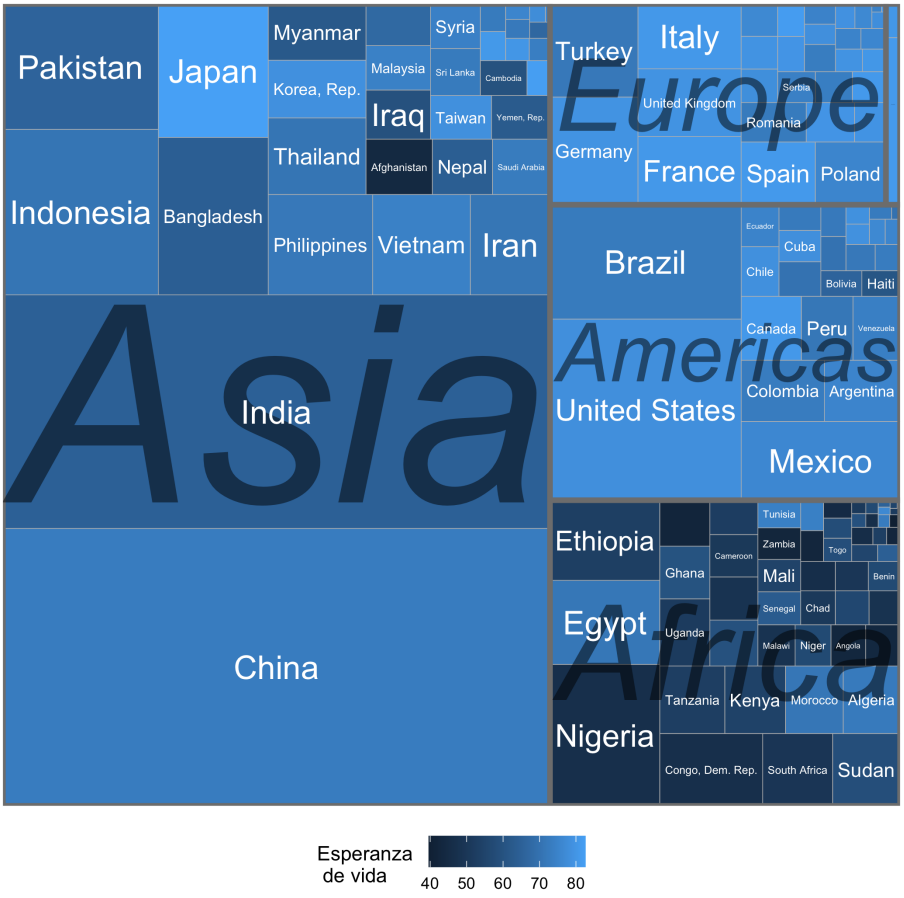

Fuente: Datos de gapminder y cálculos propios empleando el paquete treemapify.

Figura 1.5. Evolución de la tasa municipal de homicidios (por mil habitantes)

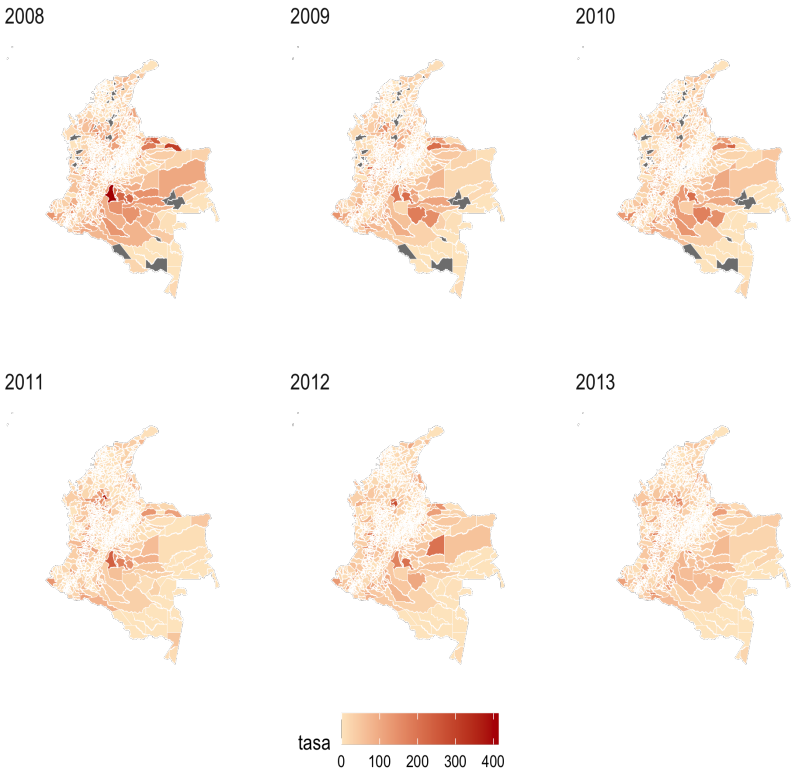

Fuente: Datos del paquete homicidios y cálculos propios empleando el paquete colmaps.

Todas las visualizaciones, en últimas, obedecen a una "gramática", como lo demuestra Wilkinson (2012). El paquete *ggplot2* facilita la construcción de las visualizaciones permitiendo implementar dicha gramática en R. Precisamente, al usar esta gramática, el paquete *ggplot2* es más intuitivo para el usuario que apenas está empezando en el universo de R.

En el Capítulo 2 analizaremos los elementos básicos de la gramática de los gráficos. En los Capítulos 3, 4 y 5 veremos los diferentes tipos de gráficos (que en este mundo se conoce como la geometría) y en el Capítulo 6 discutiremos unos trucos para mejorar la comunicación de nuestras visualizaciones.

Antes de entrar en los detalles de cómo realizar visualizaciones es importante entender la lógica que siguió el diseñador del paquete *ggplot2*. De hecho, este paquete hace parte de un conjunto de paquetes que se conocen como *tidyverse*[2]. Estos fueron diseñados para facilitar operaciones comunes de la ciencia de datos permitiendo un flujo de trabajo continuo entre las diferentes tareas de carga, transformación, modelado y visualización de datos.

1.1 El universo *tidyverse*

Los paquetes que hacen parte de *tidyverse*[3] tienen funciones que no solo permiten realizar tareas como la carga, transformación y visualización de datos, sino también la conexión entre dichas tareas[4] (ver Sección 1.2).

Estos paquetes permiten optimizar el flujo de trabajo cuando empleamos datos para sacar conclusiones (ver Figura 1.6). El flujo de trabajo inicia[5] desde la preparación y limpieza de los datos que previamente han sido recolectados y almacenados. Posteriormente se exploran los datos de manera gráfica y con estadísticas descriptivas, para pasar al modelado. Finalmente se comunican los resultados empleando visualizaciones y tablas.

[2] *tidyverse* (Wickham et al., 2019) es un paquete que contiene 8 paquetes.

[3] Observa que *tidy* significa en español ordenado y *verse* es la parte final de *universe* (universo) de ahí que también se emplee la expresión universo *Tidyverse*.

[4] Si deseas conocer mucho más del detalle de cómo fue diseñado este universo puedes consultar Wickham y Grolemund (2016) o la versión en línea del libro en el siguiente enlace: https://r4ds.had.co.nz.

[5] Para una explicación breve de las actividades en el proceso de análisis de datos puedes ver el video en el siguiente enlace: https://youtu.be/rhLWa-vOxyU .

Figura 1.6. Actividades y paquetes del Tidyverse en el flujo de trabajo del análisis de datos

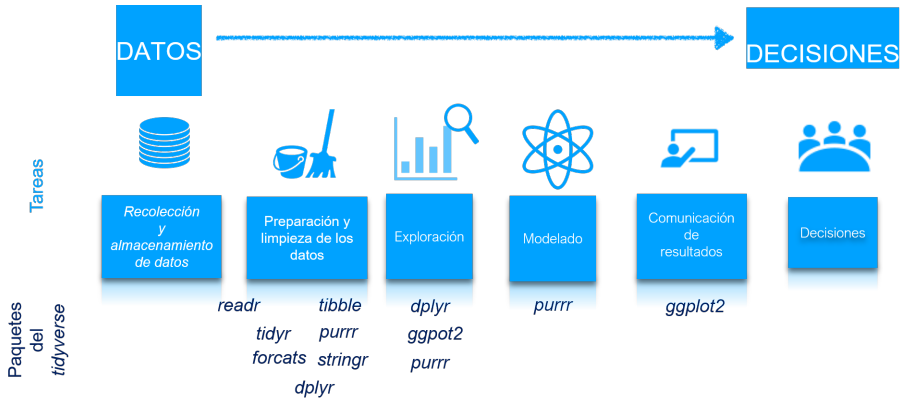

Fuente: Adaptación de Alonso y Ocampo (Alonso Cifuentes y Ocampo, 2022).

Los paquetes del *tidyverse*[6] son:

- *readr* (Wickham et al., 2018): lee datos de muchas fuentes (incluyendo formatos como .tsv y .fwf). Este paquete es útil para pasar de la actividad de recolección y almacenamiento de datos a la de preparación y limpieza (ver Figura 1.6).
- *tibble* (Müller y Wickham, 2021): guarda bases de datos de la clase *tibble* (ver Capítulo 1 de Alonso (2022) para una discusión de esta clase de objetos). Las funciones de este paquete son útiles en la actividad de preparación y limpieza de datos (ver Figura 1.6).
- *tidyr* (Wickham, 2021): permite organizar un objeto con datos de clase **data.frame** o **tibble**. Este paquete es de especial utilidad en la actividad de preparación de datos (ver Figura 1.6).
- *stringr* (Wickham, 2019): facilita el trabajo con datos que contienen carácteres (texto), lo cuál es conveniente en la limpieza de datos (ver Figura 1.6).
- *forcats* (Wickham, 2020): facilita la preparación y limpieza de variables de clase **factor** (ver Figura 1.6).
- *purrr* (Henry y Wickham, 2020): facilita la programación con funciones y vectores. Estas herramientas permiten eliminar los bucles (también conocidos como *loops*[7]), que son útiles en la ejecución de tareas repetitivas en la actividad de preparación, limpieza, exploración y modelado de datos (ver Figura 1.6).
- *dplyr*(Wickham et al., 2021): facilita el filtrado de observaciones,

[6]Para una descripción mas detallada de cada uno de los paquetes se puede consultar Alonso (2022) .

[7]Si quieres conocer sobre los *loops* en R, puedes consultar Alonso (2021) .

creación de variables y unión de objetos con datos por medio de una gramática de manipulación de datos. Para una discusión de este paquete puedes ver Alonso (2022). Este paquete es conveniente en la preparación, limpieza y exploración de los datos (ver Figura 1.6).
- *ggplot2* (Wickham, 2016): crea visualizaciones de datos siguiendo un gramática de capas, las cuales son útiles en las actividades de limpieza y exploración de datos y en la de comunicación de los resultados (ver Figura 1.6). Este libro se centra en este paquete.

Podemos emplear todas las funcionalidades del paquete *ggplot2* sin necesidad de emplear los otros paquetes del *tidyverse*. Pero, en algunas ocasiones emplear los otros paquetes de universo *tidyverse* simplifica el flujo de trabajo desde los datos originales hasta obtener la visualización. En este libro mantendremos al mínimo el uso de los otros paquetes del *tidyverse* pero en algunas ocasiones nos será difícil no emplearlos. En otras palabras, si bien evitaremos emplear el operador `pipe` (`%>%`), en algunas ocasiones será difícil no emplearlo para agilizar nuestro flujo de trabajo. Así mismo ocurrirá con los verbos de los otros 7 paquetes del *tidyverse*.

1.2 El operador `pipe`

Los paquetes del universo *tidyverse* emplean el operador `pipe` (`%>%`). Este operador permite poner en una "tubería" un objeto con datos y ejecutar diferentes operaciones sobre las observaciones (filas) o variables (columnas) sin tener que guardar los resultados intermedios. En otras palabras, el operador `%>%` permite encadenar resultados rápidamente. En Alonso (2022) encontrarás una presentación de este operador más detallada.

Veamos un ejemplo que emplea los datos del paquete *gapminder* (Bryan, 2017) (ver Capítulo 6 de Alonso y Ocampo (2022)). Este paquete tiene un objeto con datos con el mismo nombre. El objeto `gapminder` contiene las siguientes variables: país (`country`), continente (`continent`), año (`year`), esperanza de vida al nacer (`lifeExp`), población (`pop`) y PIB percápita (`gdpPercap`). Los datos van desde 1952 a 2007 de a quinquenios. Carguemos los datos y explorémoslos.

```
# cargar paquete
# install.packages("gapminder")
library(gapminder)
# cargar datos
data("gapminder")
# cargar paquete
```

```
library(dplyr)
# Mirando los datos
glimpse(gapminder)
```

```
## Warning: package 'dplyr' was built under R version 4.0.5
```

```
##
## Attaching package: 'dplyr'
```

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

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

```
## Rows: 1,704
## Columns: 6
## $ country   <fct> "Afghanistan", "Afghanistan", "Afghanistan"~
## $ continent <fct> Asia, Asia, Asia, Asia, Asia, Asia, Asia, A~
## $ year      <int> 1952, 1957, 1962, 1967, 1972, 1977, 1982, 1~
## $ lifeExp   <dbl> 28.801, 30.332, 31.997, 34.020, 36.088, 38.~
## $ pop       <int> 8425333, 9240934, 10267083, 11537966, 13079~
## $ gdpPercap <dbl> 779.4453, 820.8530, 853.1007, 836.1971, 739~
```

Supongamos que solo queremos trabajar con los promedios por continentes de la esperanza de vida al nacer para el 2007. Hacer esto con la base de R nos tomará bastantes pasos, pero con el paquete *dplyr* y el operador %>% la tarea se simplifica mucho. Por ejemplo:

```
library(dplyr)
gapminder %>%
  filter(year == 2007) %>%
  group_by(continent) %>%
  summarise(EV_prom = mean(lifeExp))
```

```
## # A tibble: 5 x 2
##   continent EV_prom
##   <fct>       <dbl>
## 1 Africa       54.8
## 2 Americas     73.6
## 3 Asia         70.7
## 4 Europe       77.6
## 5 Oceania      80.7
```

El operador %>% pasa el resultado del último cálculo al primer argumento de la siguiente función, para que no sea necesario reescribirlo o guardarlo. Con este operador los datos entran en una tubería (`pipe`) que pasa el resultado de cada uno de los pasos al siguiente y al final solo recibimos el resultado. Recuerda, es necesario cargar el paquete *dplyr* o cualquiera del conjunto que hace parte de *tidyverse* (diferente a *ggplot2*) para usar el operador %>%.

1.3 Comentarios finales

Por su gran cantidad de usuarios, hay muchos ejemplos de visualizaciones creadas con *ggplot2* disponibles en internet. Un buen ejemplo es la galería que se presenta en la *The R Graph Gallery*. Estas comunidades no solo presentan los ejemplos de las visualizaciones que podemos crear con este paquete, sino que es común que se provea el código que generó las visualizaciones. Después de finalizar la lectura de este libro, podrás entender esos códigos y adaptarlos para tu caso particular. También encontrarás en línea numerosos *blogs*[8] y foros[9] dedicados a responder dudas sobre errores en este paquete.

No podemos terminar este primer capítulo sin recordar que *ggplot2* no es el único paquete para hacer gráficos. Dentro de la base (o *core*) de R hay otras opciones para "mapear" datos a una visualización, sin tener necesidad de recurrir a instalaciones externas. Lo que hace a este paquete tan especial es que obedece una gramática preestablecida en la estadística y lo traduce a programación de R. Esto hace que su implementación no sea tan compleja como puede llegar a ser la construcción de una visualización en la base de R. El siguiente capítulo te enseñará los elementos esenciales de la gramática de las visualizaciones.

Finalmente, al tener muchos usuarios de uso, existen numerosas comunidades de usuarios que se reflejan en diversas discusiones sobre la realización de gráficos de manera eficiente en los diferentes *blogs* de R.

[8]Por ejemplo, *R-Blogger* es un sitió que se dedica a recoger entradas de diferntes *blogs* de la comunidad de R (https://www.r-bloggers.com).

[9]Por ejemplo, *Stackoverflow* es un foro muy común para usuarios en R que tiene una sección especial para ggplot (https://stackoverflow.com/questions/tagged/ggplot2).

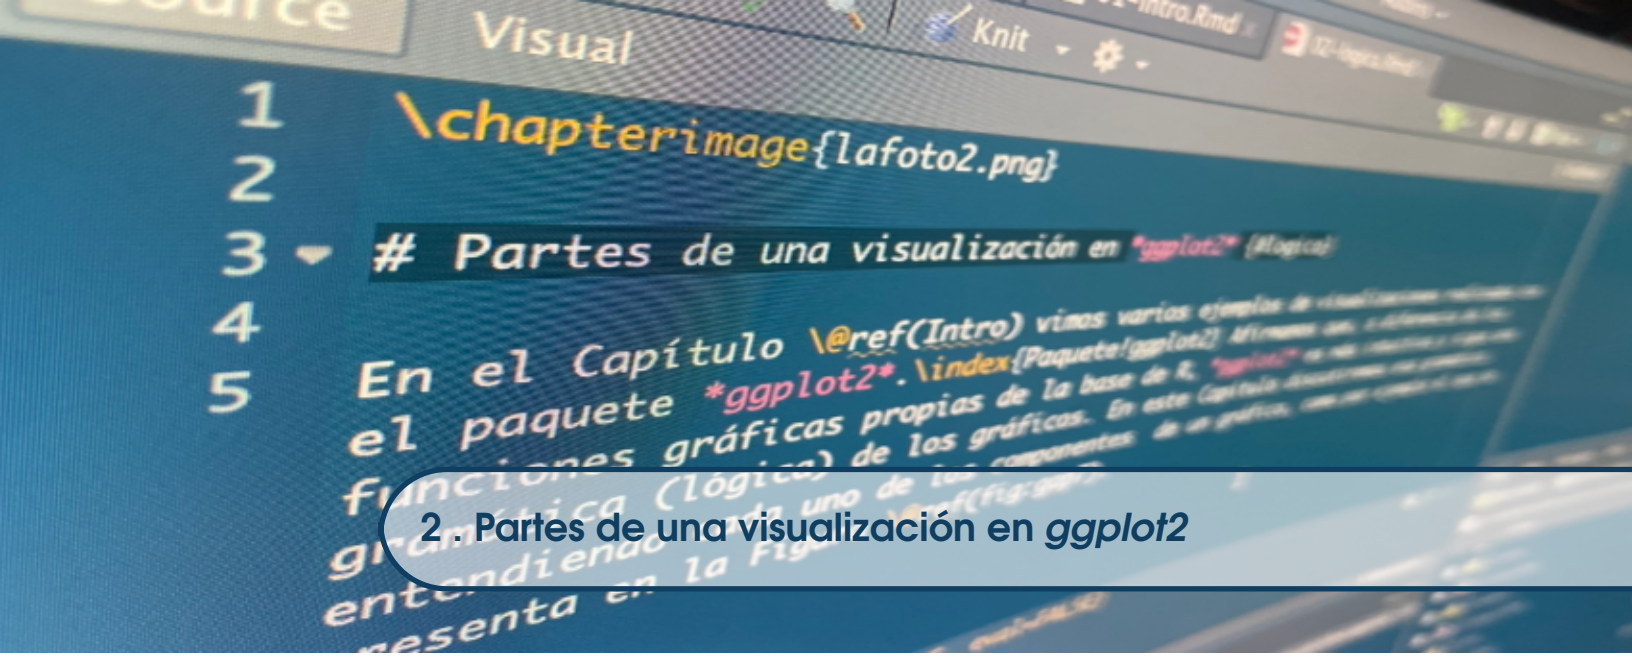

2 . Partes de una visualización en *ggplot2*

En el Capítulo 1 vimos varios ejemplos de visualizaciones realizadas con el paquete *ggplot2*. Afirmamos que, a diferencia de las funciones gráficas propias de la base de R, *ggplot2* es más intuitivo y sigue una gramática (lógica) de los gráficos. En este Capítulo discutiremos esa gramática entendiendo cada uno de los componentes de un gráfico, como por ejemplo el que se presenta en la Figura 2.1.

La Figura 2.1 parte de unos datos (que salieron del paquete *gapminder* (Bryan, 2017)) y unas decisiones de cómo visualizar esos datos. Reflexionemos un poco sobre todas las decisiones que se tomaron antes de construir el gráfico. Después de tener los datos, se parte de una idea de qué variables "mapear" (graficar) en cada uno de los ejes. En este caso, el PIB percápita (`gdpPercap`) y la esperanza de vida al nacer (`lifeExp`). Se eligió cómo representar cada observación (en este caso con puntos) y cómo el color de estos puntos tendría una variable "mapeada". Se asignó el continente (`continent`) al color. También, se decidió de manera implícita que el tamaño del punto no tendría ningún significado. Adicionalmente, se seleccionó en qué unidades medir los ejes (las coordenadas). Finalmente, se decidió cómo sería el diseño del gráfico, al escoger la posición de los nombres de las variables en los ejes y si el cuerpo del gráfico tendría grilla[1] y el color del fondo.

En este capítulo discutiremos cada uno de esos componentes y veremos la *jerga* que se emplea en el paquete *ggplot2* para referirse a ellos.

[1] En otras palabras, las lineas horizontales y verticales al interior de la visualización. A estas líneas también se les conoce como retícula (en inglés *grid lines*).

Figura 2.1. Relación entre el PIB percápita y la expericencia de vida al nacer por país (2007)

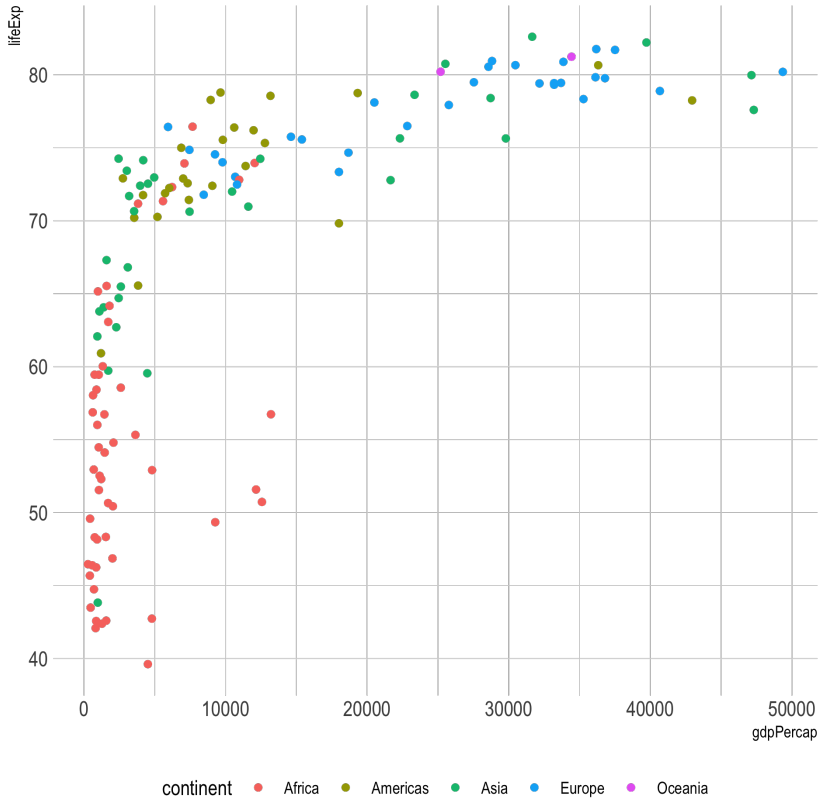

Fuente: Datos del paquete gapminder.

2.1 Componentes

Veamos formalmente cómo *ggplot2* emplea la gramática de los gráficos de Wilkinson (2012). Es decir, veamos cuáles son los componentes y cómo estos se sobreponen para obtener un gráfico. En este contexto, un gráfico está compuesto por diferentes capas que se sobreponen de tal manera que el resultado final es una visualización. En la Figura 2.2 se presentan las diferentes capas que componen un objeto de clase **ggplot**.

Figura 2.2. Capas de una visualización construída con ggplot2

Fuente: Elaboración propia a partir de Wickham (2016) y Eilkinson (2012).

No todas las capas son necesarias para construir una visualización en *ggplot2*, pero cada una aportará al producto final un elemento diferente. Veamos cada uno de estas capas (*layers* en inglés):

- ***Datos*** o data: es la primera capa necesaria para realizar visualizaciones (ver Figura 2.2). Es la base fundamental para construir la

visualización y por tanto es una parte obligatoria en la construcción de una visualización en este paquete. Esta capa llama a los datos, que deben estar en un objeto de clase **data.frame**[2] o **tibble**[3]. En la Figura 2.1 esta capa corresponde al objeto `gapminder` (**data** = gapminder).

- ***Aesthetics***: en esta capa se indican las variables que se van a "mapear" (graficar) en los diferntes elementos del gráfico, como ejemplo los ejes, el color y el tamaño de los puntos. Una traducción literal de esta capa sería "estética", pero de pronto no es una buena traducción. Esta capa indica qué variables del *data.frame* se mapean a el eje horizontal (denotado por **x**) y cuál al eje vertical (**y**). También podemos mapear en esta capa el color (**col**), como en la Figura 2.1 donde el continente (que es una variable cualitativa) se mapeó al color de cada punto (**col = continent**). En dicha figura, la variable cuantitativa PIB percápita se representa en el eje horizontal (**x = gdpPercap**) y la esperanza de vida al nacer (variable cuantitativa) en el eje vertical (**y = lifeExp**). Adicionalmente, podemos mapear variables (si tiene sentido) al tamaño (**size**) y otros elementos como la forma del punto. Al igual que la primera capa, esta es obligatoria; constituyéndose, con la capa de los datos, en uno de los tres pilares de cualquier visualización que armemos con *ggplot2*. Esta capa es conocida en el paquete como **aes**.
- ***Geometría***: esta capa le indica a R qué tipo de visualización se desea obtener. Es decir, cuál es la geometría que se desea adoptar para mostrar los datos. Por ejemplo, la geometría podría ser emplear barras, líneas, puntos, histogramas, entre otros. En el caso particular de la Figura 2.1 la geometría seleccionada fue los puntos (**geom_point**). Hay distintas opciones que se explorarán más adelante en los Capítulos 3, 4 y 5. Esta capa es obligatoria y constituye el tercer pilar indispensable en toda visualización de *ggplot2*.
- ***Facets***: esta capa permite descomponer un gráfico en sub-gráficos (cuadrículas o facetas) según una variable cualitativa. Por ejemplo, en vez de usar colores para distinguir los continentes, como se hace en la Figura 2.1, podríamos construir 5 sub-gráficos cada uno para un continente como en la Figura 2.6. Las facetas sirven para comparar grupos, separándolos y así facilitando la identificación de los grupos. No es una capa obligatoria.
- ***Estadísticas***: esta capa permite adicionar información estadística que permita resumir los datos. Por ejemplo, se puede adicionar una línea de tendencia para los datos. No es obligatoria.
- ***Escalas***: esta capa permite indicar en qué escala se presentan los datos en cada uno de los ejes. Por ejemplo, en algunas ocasiones

[2] En el Capítulo 5 de Alonso y Ocampo (2022) puedes encontrar una introducción a esta clase de objetos.

[3] En el Capítulo 1 de Alonso (2022) se presenta una breve introducción a esta clase de objetos.

se podría desear presentar uno de los dos ejes en escala logarítmica. No es obligatoria.
- ***Coordenadas***: esta capa determina cómo se combinan las variables seleccionas para los ejes `x` (horizontal) y `y` (vertical) en la capa de estética. En últimas esta capa define el espacio en el que se mapearán los datos. Por ejemplo, en algunas ocasiones será útil poner límites a los ejes, intercambiar lo que se presenta en un eje con el otro, o asegurarnos que los dos ejes tienen la misma magnitud.
- ***Tema***: es la capa destinada a la apariencia final de la gráfica. Podemos encontrar unos temas predeterminados cargados con el paquete *ggplot2* y también se puede crear un tema para que se adapte a la imagen institucional o al tipo de diseño de todo el documento. También existen algunos paquetes que incluyen temas adicionales. Aquí se modifica el color del fondo, ejes, tamaños, grilla, posición de los nombres de los ejes, entre otros. No es obligatoria.

Veamos un ejemplo para entender mejor cada capa y sus argumentos.

2.2 Primeros pasos con *ggplot2*

Para empezar a trabajar con visualizaciones en R debemos instalar el paquete *ggplot2* (Wickham, 2016), en caso de que no esté instalado en el equipo. Los **paquetes** incluyen diversas funciones, para tareas generales o específicas[4]. En especial, este paquete contiene herramientas de visualización. Para proceder a la instalación, puedes emplear la función **install.packages()**.

```
install.packages("ggplot2")
```

La instalación de un paquete solo es necesaria una vez. Recuerda que tenemos que pedirle a R que cargue el paquete cada vez que iniciemos una nueva sesión. Para esto, emplea la función **library()** . Carguemos el paquete *ggplot2*.

```
library(ggplot2)
```

Para nuestro ejemplo usaremos el objeto de datos `gapminder` del paquete **gapminder** (Bryan, 2017) que ya empleamos en la Sección 1.2. Carga el objeto `gapminder`.

[4]El Capítulo 7 de Alonso y Ocampo (2022) presenta una breve introducción a los paquetes en R.

```
# cargar paquete
# install.packages("gapminder")
library(gapminder)
# cargar datos
data("gapminder")
```

Veamos cómo materializar lo descrito en la sección anterior (Sección 2.1). Veíamos que de las siete capas descritas, las capas de ***Datos***, ***Aesthetics*** y ***Geometría*** son esenciales. Las dos primeras capas, se especifican empleando la función **ggplot()** . El primer argumento de esta función corresponde a la primera capa: los datos[5]. El argumento **data** puede ser un objeto de clase *data.frame* o `tibble`.

```
ggplot(data = gapminder)
```

Figura 2.3. Primera capa (datos) de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007)

Fuente: Datos del paquete gapminder.

[5]Si se emplea el operador %> % este argumento se puede pasar desde la línea anterior.

Correr solo esta parte de la función tendrá como resultado un gráfico en blanco (ver Figura 2.3), porque aún nos faltan los otros dos pilares necesarios para una visualización: Las capas ***Aesthetics*** y ***Geometría***.

La segunda capa, ***Aesthetics***, se especifica como otro argumento de la función **ggplot()**. La función **aes()** permite especificar cómo se mapearán las variables a los diferentes elementos de la visualización. Para este primer ejemplo, se quiere mostrar la relación entre dos variables numéricas (o cuantitativas): la expectativa de vida al nacer (`lifeExp`) y el PIB percápita (`gdpPercap`). Entonces, se representará en el eje horizontal (**x**) la variable `lifeExp` y al eje vertical (*y*) la variable `gdpPerCap`, dentro del argumento **aes()**.

Es decir, la primera y segunda capa de la figura corresponderá a la siguiente línea de código:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))
```

Figura 2.4. Primera y segunda capa de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007)

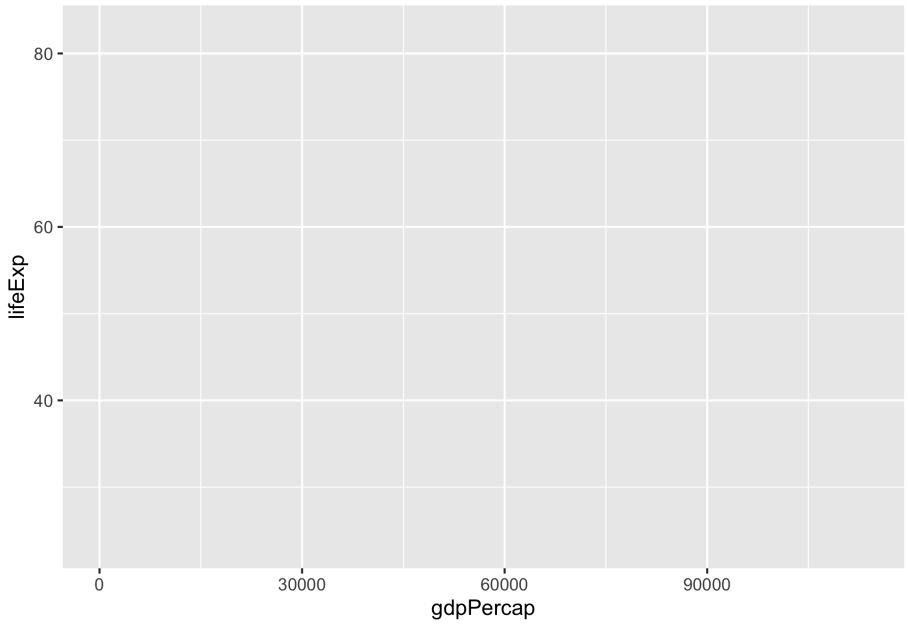

Fuente: Datos del paquete gapminder.

Nota que al correr esta línea, aparece el plano cartesiano en el que

se ubicarán los datos, pero no los datos en sí. Esto sucede porque aún nos falta el último pilar: la ***Geometría*** (ver Figura 2.4). Es decir, aún no hemos especificado cómo se mapearán los datos. En otras palabras, no se ha especificado el tipo de visualización que vamos a emplear.

La capa de ***Geometría*** (**geom** en la jerga de *ggplot2*) se especifica mediante una segunda función. Existen diferentes tipos de gráficas como por ejemplo: histogramas, líneas, barras y puntos. Dado que tenemos diferentes posibilidades de geometría, tendremos diferentes funciones para cada una de las posibles geometrías (en los próximos capítulos discutiremos sobre estos temas). Estas funciones se caracterizan por empezar con el prefijo **geom_**. Por ejemplo, para la visualización que estamos construyendo se desea un diagrama de dispersión en el que cada dato se representa por puntos. Así, la función correspondiente será: **geom_point()**. Esta capa se suma a las dos capas anteriores de la siguiente manera:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()
```

Observa que esta capa se agrega a las dos anteriores con el signo de suma (+). En la Figura 2.5 podemos observar las tres primeras capas esenciales: ***Datos***, ***Aesthetics*** y ***Geometría***.

Figura 2.5. Primeras tres capas de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007).

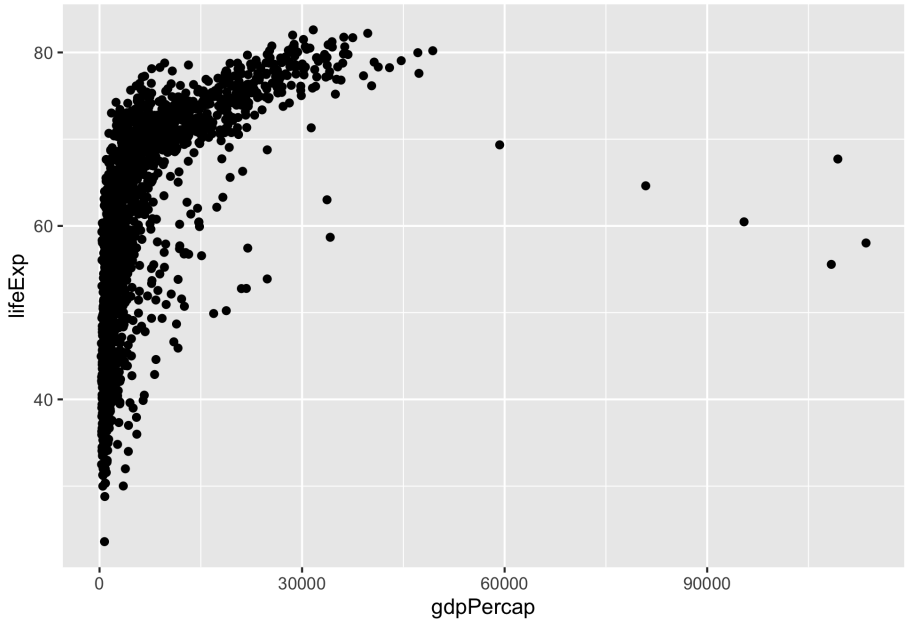

Fuente: Datos del paquete gapminder.

Hasta aquí tenemos las capas necesarias para crear una visualización, pero podemos adicionar otras para mejorarla. Las siguientes capas se pueden agregar, si se desea, en cualquier orden. Por ejemplo, en este caso especial de esta visualización, tendría sentido incluir la capa de ***Facets***.

El objeto `gapminder` también contiene la variable continente (`continent`). Si queremos entender la distribución de las dos variables bajo análisis en los diferentes continentes, podemos emplear la capa de ***Facets*** para dividir los datos de tal manera que grafiquemos para cada continente la relación entre ellas (ver Figura 2.6).

Esta capa se puede adicionar con la función **facet_grid()**. Esta función crea una grilla (*grid* en inglés) o parrilla de gráficos, separando los datos de acuerdo a la variable que se emplee como argumento. Siguiendo la tradición del lenguaje de R, la variable por medio de la cuál se quieran dividir los gráficos debe estar precedida del operador virgulilla[6] (~) . Regresando a la figura que estábamos construyendo, la capa de ***Facets*** se puede agregar para que los datos sean visualizados por continente, como se muestra en el siguiente código:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point() +
  facet_grid(~ continent)
```

Nota que otra forma de visualizar las diferencias entre continentes podría ser mapear al color la variable continente y no usar la capa de ***Facets***. ¡Inténtalo! El resultado sería algo muy similar a la Figura 2.1. La diferencia es que en la Figura 2.1 se presentan solo datos para el año 2007 y tu gráfica debe tener datos para toda la muestra. En ese caso parece mejor transmitir la idea de las diferencias entre continentes la capa de ***Facets*** que mapear los continentes al color del punto. Este tipo de decisiones, sobre qué comunica mejor tu idea siempre estará presente al momento de hacer visualizaciones. Lo mejor será **siempre ensayar muchas opciones antes de decidir cuál visualización será la mejor para comunicar tus ideas**.

Ahora podemos jugar un poco con la capa de ***Escalas***[7] para ayu-

[6] Virgulilla es el "palito curvo" que se emplea en el español encima de la letra ene (n) para convertirla en eñe (ñ). En inglés este operador (~) se conoce como *tilde*. Este operador se emplea en la base de R para definir la relación entre la variable dependiente y las variables independientes en la fórmula de un modelo estadístico. La variable a la izquierda del operador ~ es la variable dependiente y la o las variables a la derecha de éste son las variables independientes. Siguiendo esa tradición, en *ggplot2* se emplea ~ para determinar que la capa de ***Facets*** dependerá de una variable **x**. Es decir, **~ x**.

[7] Estas capas que no son pilares de la visualización se pueden adicionar en cualquier orden, pero en algunas ocasiones el resultado puede cambiar. En un momento te darás cuenta que por razones pedagógicas cambiamos el orden que se presentó inicialmente en el la Figura 2.2.

Figura 2.6. Primeras tres capas y capa Facets de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007)

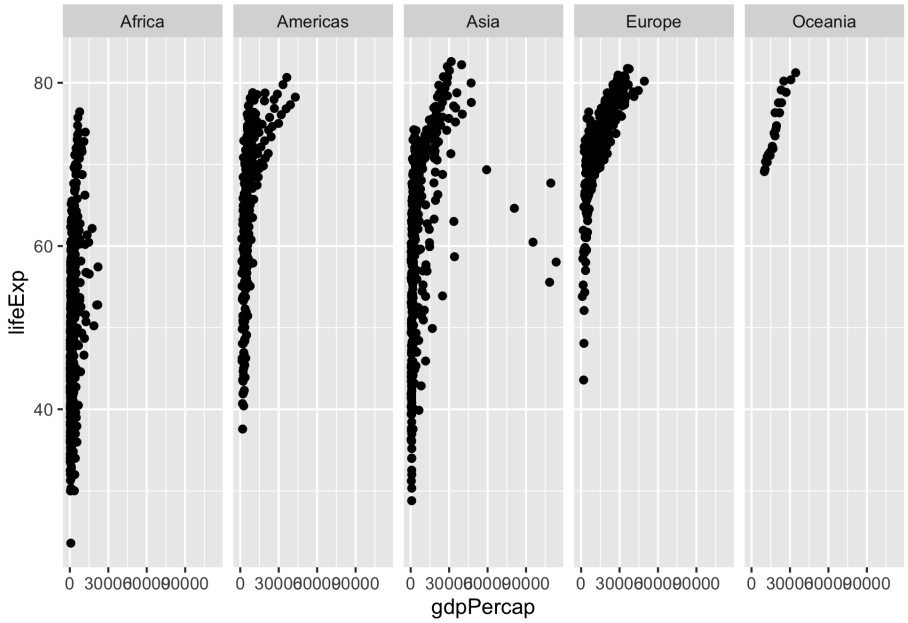

Fuente: Datos del paquete gapminder.

darnos a comunicar un mensaje. La capa de **Escalas** permite cambiar la escala en la que se mide un eje y algunos detalles de cada uno de los ejes como los límites o las etiquetas de cada eje. En otras palabras, esta capa controla los detalles de cómo se traducen los valores de los datos a las propiedades visuales.

Por ejemplo, podríamos cambiar la escala en la que se presentan los datos del PIB percápita (`gdpPercap`) de dólares por persona a una escala logarítmica (logaritmo base 10) empleando la función **scale_x_log10()**. Regresando a nuestro ejemplo, cambiemos la escala del eje horizontal para obtener la Figura 2.7 empleando el siguiente código:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10()
```

Figura 2.7. Capa Facets y Escalas de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007)

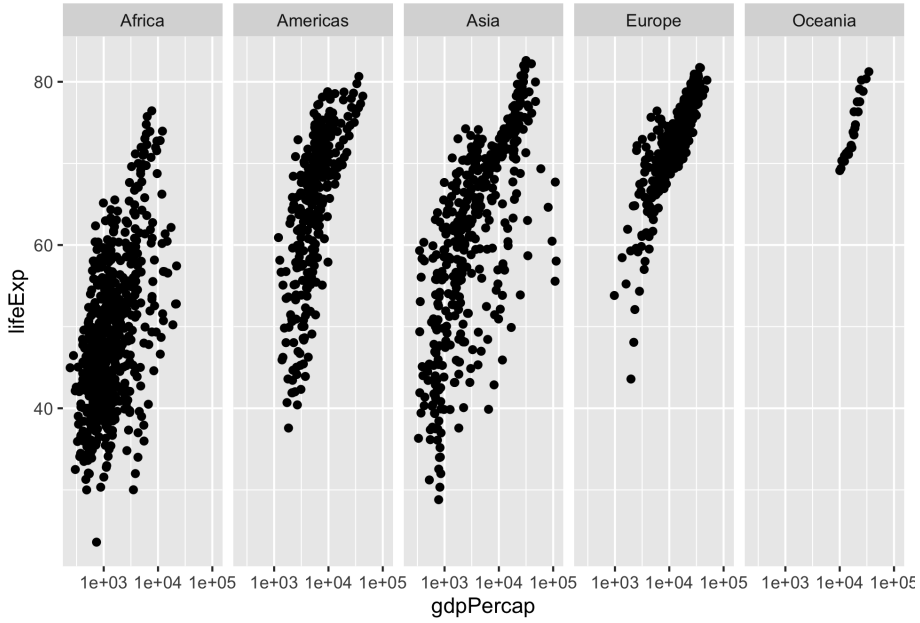

Fuente: Datos del paquete gapminder.

El paquete *ggplot2* tiene a disposición diferentes transformaciones y

operaciones que podemos hacer con las escalas de los ejes, todas esas funciones empiezan por el prefijo **scale_**[8].

La capa **Escalas** también tiene funciones que no empiezan con el prefijo **scale_** que modifican elementos de los ejes y los títulos. Por ejemplo, la función **labs()** permite agregar un título (argumento **title**), subtítulo (argumento **subtitle**) y la fuente (argumento **caption**). También tenemos las funciones **xlab()** y **ylab()** que permiten cambiar las leyendas de los ejes que por defecto es el nombre de la variable mapeada. Esta capa también tiene funciones que permiten cambiar los limites de las escalas que se presentan en cada eje (**xlim()** y **ylim()**). Tienes que tener cuidado con estas dos últimas funciones, pues cualquier dato fuera de los límites se desechará.

Juega un poco con estas funciones para entender cómo funcionan. Intenta correr el siguiente código y ver el efecto que tiene sobre tu visualización:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10() +
  labs(
  title = "Relación entre  PIB percápita y
          Expectativa de vida al nacer por país",
  subtitle = "(1952 - 2007)",
  caption = "Fuente: Datos de gapminder") +
  xlab("PIB percápita en logaritmos") +
  ylab("Esperanza de vida al nacer en años")
```

La capa de **Coordenadas** es la que le dice a *ggplot2* cómo combinar la variable en la capa de **Estética** mapeada en `x` y `y` para construir la visualización en dos dimensiones. Comúnmente estamos acostumbrados a emplear coordenadas cartesianas (el plano cartesiano) para mapear los datos. Por defecto *ggplot2* emplea coordenadas cartesianas (función **coord_cartesian()**[9]). Una función de esta capa que puede ser útil

[8]Por ejemplo, están las funciones **scale_y_continuous()** y , **scale_y_reverse()**, que permiten convertir la escala del eje vertical (`y`) a una variable continua y cambiar a un orden descendente los valores del eje, respectivamente. ¡Intenta jugar con todas estas funciones!

[9]Esta función permite asignar límites para en los ejes para los que se presentará los datos. Esto genera un *zoom* en una parte de los datos. Intenta adicionar al código que generó la Figura 2.7 la siguiente línea de código `coord\_cartesian(ylim = c(40,60))`. Recuerda añadir el signo + antes de incluir esta nueva capa. Esto genera una visualización con solo los datos que están entre los límites. La diferencia entre expresar los límites de los ejes en la capa de **Coordenadas** y de **Escalas**, es que en el segundo caso los datos que estén por fuera se omiten y no se tienen en cuenta para ningún cálculo, mientras que en el segundo caso solo no se visualizan. Esto tiene un impacto sobre la visualización en especial cuando se adicione la capa de **Estadística** como se mostrará en el siguiente pie de página.

es **coord_flip()**, que invierte los ejes. Para un ejemplo de la utilidad de esta función puedes ver las Figuras 6.1 y 6.2 del Capítulo 6. Por ahora, intenta el siguiente código:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10() +
  coord_flip()
```

Otra función útil de esta capa es **coord_fixed()**, la cual fija la relación entre el espacio que ocupa el eje x y el eje y. Con el argumento **ratio** podemos establecer el número de unidades en el eje vertical que equivalen a una unidad en el eje horizontal. El valor por defecto es uno (`ratio = 1`). Una razón mayor a uno, implica que las unidades del eje horizontal serán más largas y viceversa. Por ejemplo, intenta el siguiente código y juega con el argumento **ratio**:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10() +
  coord_fixed(ratio = 0.05)
```

La capa de **Coordenadas** tiene más funciones para hacer mapas (por ejemplo, **coord_map()**, **coord_quickmap()** y **coord_sf()**) y coordenadas polares (**coord_polar()**). Como con cualquier otra función de este paquete, si necesitas alguna de ellas podrás encontrar una documentación muy completa en línea.

La capa de ***Estadísticas*** nos puede servir para reforzar una idea que queremos transmitir con una visualización. Por ejemplo, parece evidente que existe una relación positiva y lineal entre la expectativa de vida al nacer (`lifeExp`) y el PIB percápita (`gdpPercap`) (en logaritmos) (ver Figura 2.7). Para mostrar esto visualmente, podríamos incluir una linea de regresión que muestre la relación lineal entre las dos variables. Existen diferentes tipos de estadísticas que nos podrían ayudar a construir nuestra visualización. Estas funciones se caracterizan por empezar con el prefijo **stat_**. Por ejemplo, la función **stat_smooth()** ayuda a trazar una linea "suavizada" que se ajuste a los datos. Esta tiene como argumento el método que queremos emplear para trazar la linea de suavización. Por ejemplo si fijamos **method = "lm"** como método, se está indicando que busque una relación lineal (*Lineal Model*, por sus siglas en inglés) (ver Figura 2.8).

También podemos modificar el color de la linea de suavización (en este caso la recta de regresión) con el argumento **col**. Si no se especifica

un color, el color será azul por defecto. En nuestro ejemplo tendremos lo siguiente:

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10() +
  stat_smooth(method="lm", col="red")
```

Figura 2.8. Capa Facets, Escalas y Estadísticas de la Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007)

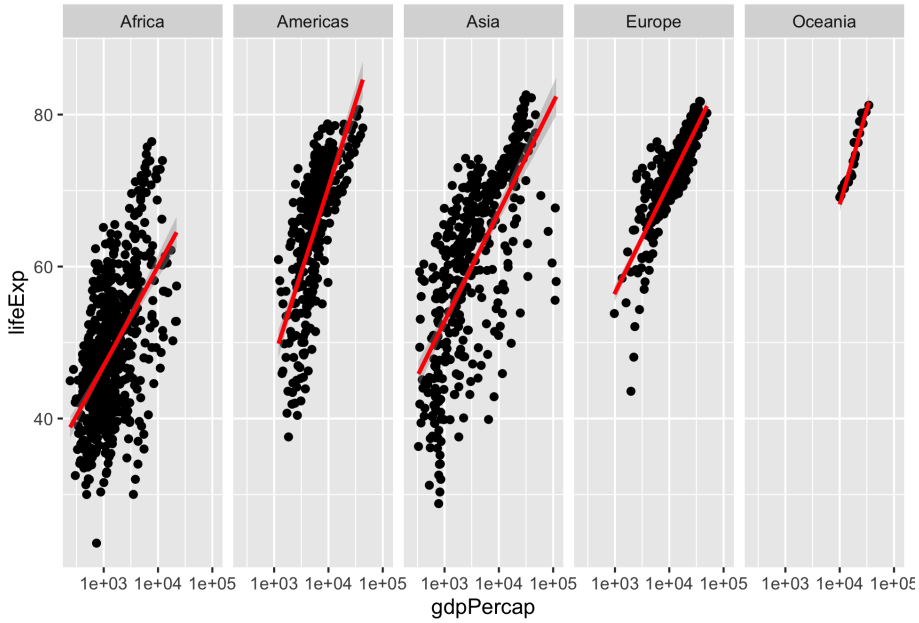

Fuente: Datos del paquete gapminder.

Observa que en la Figura 2.8 se ha trazado una línea de regresión para cada continente empleando todos los datos del respectivo continente[10] esto transmite mejor la idea de que existe una relación lineal

[10]Es interesante ver el efecto que tiene cambiar los límites de los ejes en la capa de **Escalas** o en la de **Coordenadas**. Adiciona primero al código que generó la Figura 2.8 una nueva línea modificando la capa de **Coordenadas** (recuerda adicionar el signo + al final de la línea anterios): `coord\_cartesian(ylim = c(40,60))`. Esto muestra exacatmane las mismas líneas de regresión de la Figura 2.8, pero haciendo un acercamiento a los datos que presentan una expectativa de vida al nacer entre 40 y 60 años. Ahora en vez de

positiva entre el logaritmo del PIB percápita y la esperanza de vida al nacer. Típicamente esta capa se emplea para transmitir algún hallazgo en la exploración o el modelado de los datos.

Nuestra visualización ha cambiado sustancialmente desde la que teníamos en la Figura 2.5. Y podemos continuar modificando nuestra visualización con la capa de ***Tema***. Como se mencionó en la sección 2.1, el paquete *ggplot2* viene con temas predeterminados que determinan cómo es el fondo de la figura, la posición y el tamaño de los nombres de los ejes. Pero este paquete también brinda la opción de crear nuevos temas, para poder agregar logos de empresas, tamaños específicos de los elementos, entre otras opciones. En general, el tema ayuda a que la visualización sea estéticamente más acorde al documento donde se va a mostrar (ver Figuras del Capítulo 1).

Dentro de los temas disponibles directamente en este paquete están **theme_minimal()**, **theme_classic()**, **theme_bw()**, entre otros. Siguiendo la misma gramática de las anteriores capas, esta se agrega sumándola a las anteriores. En este caso las funciones de tema (todas inician con el prefijo **theme_**) no necesitan argumentos para funcionar. Por ejemplo, el siguiente código incorpora el tema minimalista (**theme_minimal()**) (ver Figura 2.9).

```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp))+
  geom_point()+
  facet_grid(~continent)+
  scale_x_log10() +
  stat_smooth(method="lm", col="red") +
    theme_minimal()
```

modificar la capa de **Coordenadas**, modifiquemos la de **Escalas** incluyendo el siguiente código: `ylim(40,60)`. En esta oportunidad la línea de regresión para cada continente se calculó incluyendo solo los datos con una esperanza de vida al nacer entre 40 y 60. Ahí está la diferencia de emplear una de las dos capas para definir el límite de los datos. Todo dependerá de lo que quieras comunicar con tu visualización.

Figura 2.9. Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007) con tema minimalista

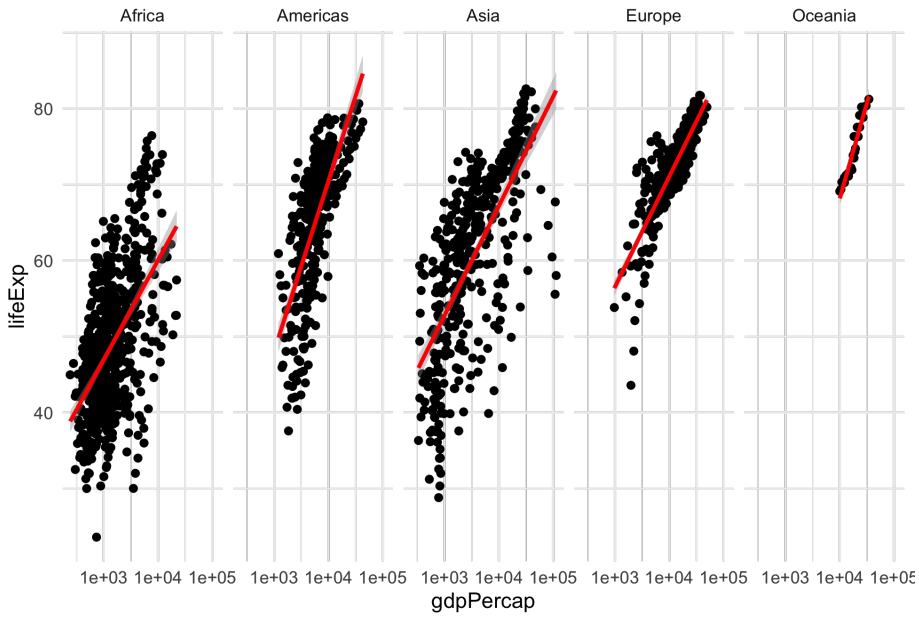

Fuente: Datos del paquete gapminder.

Ahora puedes intentar jugar con las diferentes opciones de temas. Por ejemplo, la Figura 2.10 emplea la función **theme_classic()**. Con estas ocho capas, el paquete *ggplot2* nos brinda una gran flexibilidad para hacer visualizaciones rápidamente.

Figura 2.10. Figura de relación entre PIB percápita y Expectativa de vida al nacer por país (1952 - 2007) Con tema clásico

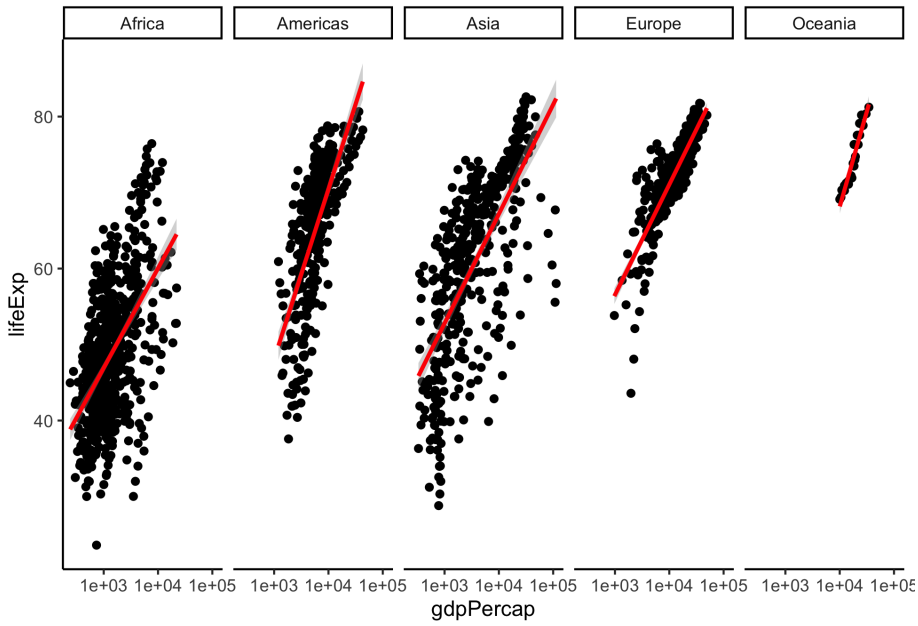

Fuente: Datos del paquete gapminder.

Para resumir, en la Figura 2.11 se resume de manera esquemática cada una de las capas y el correspondiente código empleado para generar la Figura 2.9

Figura 2.11. Capas de la Figura 2.9. y su respectivo código

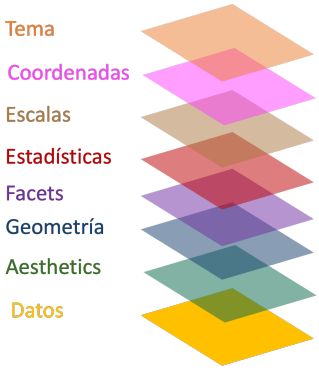


```
ggplot(gapminder, aes(x = gdpPercap, y = lifeExp)) +
         geom_point() +
        facet_grid (.~continent) +
        stat_smooth(method ="lm", col="red") +
        scale_x_log10() +
        theme_minimal()
```

Fuente: Elaboración propia a partir de Wickham (2016) y Eilkinson (2012).

2.3 Comentarios finales

Antes de continuar, es importante mencionar que este paquete y otros adicionales, permiten incluir más capas y funciones de las que vimos en este capítulo. Por ejemplo, se pueden usar funciones de otros paquetes para agregar paletas de colores específicas, títulos, entre otras características, que ayudarán a mejorar la visualización.

Son tantas las opciones que con seguridad te podrás divertir experimentando poco a poco con las diferentes alternativas disponibles. Hacer buenas visualizaciones no es tarea fácil y siempre implicará probar muchas opciones de capas, incluyendo la geometría.

Como se definió en la Sección 2.1, la capa de ***Geometría*** indica el tipo de visualización que se construirá. La selección de la geometría adecuada es tal vez la decisión más importante para obtener una visualización poderosa. Para escoger la capa de ***Geometría*** debemos preguntarnos qué queremos mostrar con ella (ver por ejemplo Abela (2008) o Alonso y González (2012)). En la Figura 2.12 se presenta un diagrama que te puede ayudar para decidir que tipo de gráfico (capa de ***Geometría***) emplear según la intención y la clase de variable que se tenga.

Figura 2.12. Tipos de gráficos más comunes según lo que se desea comunicar y la clase de variable

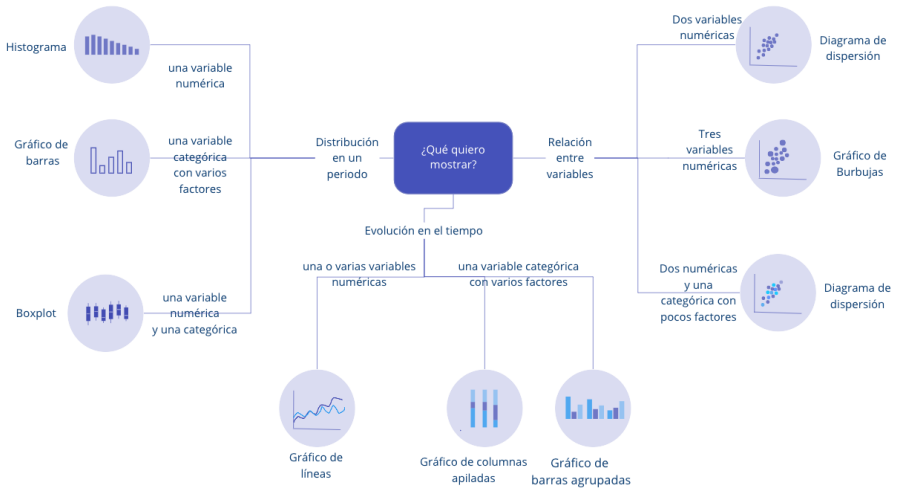

Fuente: Adaptación de Alonso y González (2012).

En el Capítulo 3 discutiremos los gráficos más empleados para mostrar la distribución de los datos (ver Figura 2.12). En el Capítulo 4 las visualizaciones más empleadas para mostrar la evolución de una variable (ver Figura 2.12) y en el Capítulo 5 aquellas para mostrar relaciones entre variables.

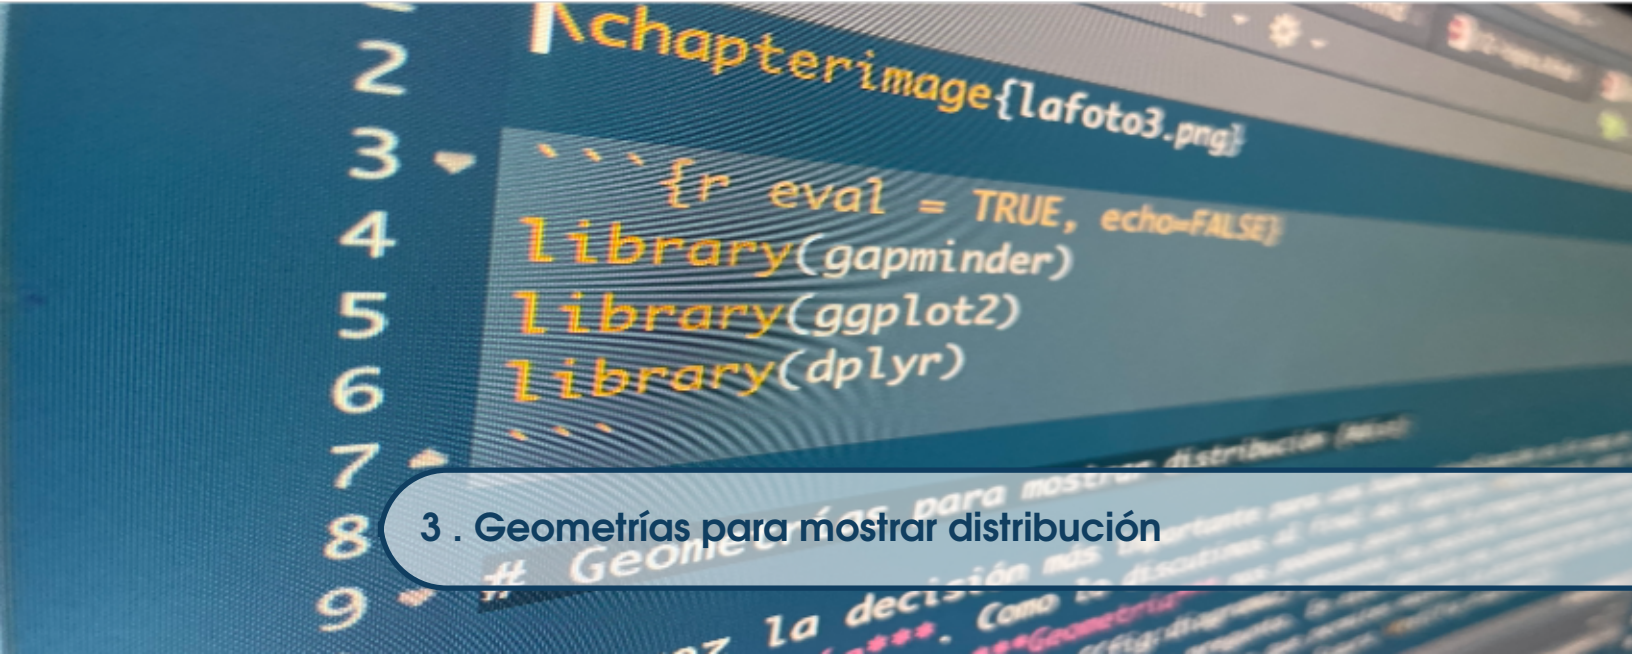

3 . Geometrías para mostrar distribución

Tal vez la decisión más importante para una buena visualización es la capa de ***Geometría***. Como lo discutimos al final del Capítulo 2, para la selección de la ***Geometría*** nos podemos guiar con la pregunta ¿qué queremos mostrar? La Figura 3.1 presenta las posibles visualizaciones para las posibles respuestas a esta pregunta. En este Capítulo nos concentraremos en cómo implementar los gráficos más comunes que permiten mostrar la distribución de una o varias variables (ver área sombreada de la Figura 3.1).

Los gráficos más comunes para mostrar la distribución de una o varias variables son[1]:

- **Histograma**
- **Gráfico de barras**
- **Boxplot** o Diagrama de cajas[2].

Estos gráficos nos permiten representar todas las observaciones de la variable, cuáles son más frecuentes, cuál es la tendencia central de los datos y su dispersión. En otras palabras, estas visualizaciones están diseñadas para mostrar rápidamente cómo se comportan todos los datos. En general estas geometrías hacen más sencillo mostrar grandes cantidades de datos.

[1] Las gráficas de tortas no son recomendables. Como se discutirá con más detalle en el Capítulo 6, el gráfico de torta **no es una buena elección** debido a que el ojo humano no es bueno calculando los ángulos. ¡No se recomienda emplear esta visualización! Existen mejores alternativas.

[2] También conocido como diagrama de cajas y bigotes.

Figura 3.1. Tipos de gráficos más comunes según lo que se desea comunicar y la clase de variable.

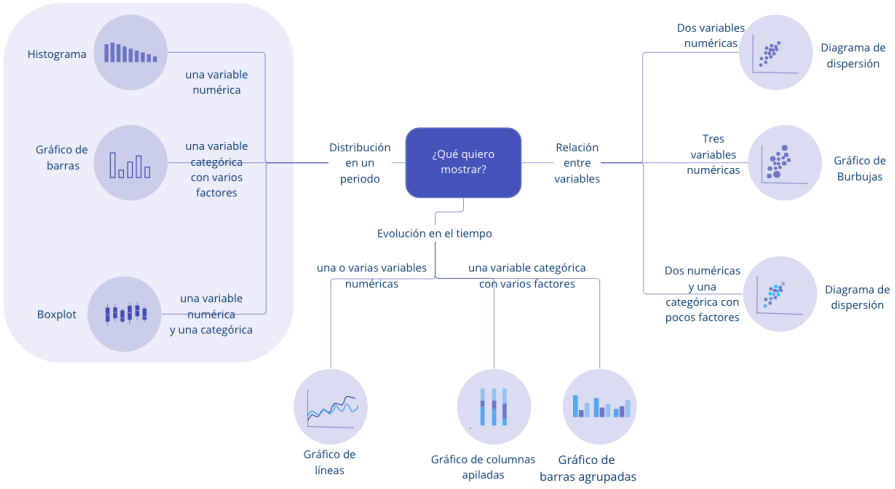

Fuente: Adaptación de Alonso y González (2012).

3.1 Histograma

Los histogramas están diseñados para mostrar la distribución de una variable de clase **numeric** (variables cuantitativas contínuas) o de clase **integer**(variables cuantitativas discretas). Un histograma agrupa los datos en intervalos pequeños que se miden típicamente en el eje horizontal y en el eje vertical se representa la frecuencia de aparición de las observaciones dentro de los límites del intervalo. La función para este tipo de gráficos es **geom_histogram()**.

Veamos un ejemplo con los datos, empleados en el Capítulo 2, del objeto `gapminder` del paquete del mismo nombre. Representemos la distribución de la expectativa de vida al nacer de todos lo países para el año 2007. Carguemos los paquetes y filtremos los datos para el año 2007. Esta será la primera capa. Ahora, empleemos el paquete *ggplot2* para construir el histograma. Necesitamos enviar a la capa de datos el objeto `gapminder`, en la capa de ***Aesthetics*** especificar la variable que mapearemos en el eje **x**. Después, la capa de ***Geometría*** corresponderá a **geom_histogram()**. El siguiente código genera la Figura 3.2

```
# cargamos los paquetes
library(ggplot2)
library(dplyr)
```

```
library(gapminder)

# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x=lifeExp)) +
    geom_histogram() +
    labs( y="Frecuencia",
          x="Exp. de vida") +
    theme_minimal()
```

Figura 3.2. Histograma de la esperanza de vida al nacer de todos los países del mundo (2007)

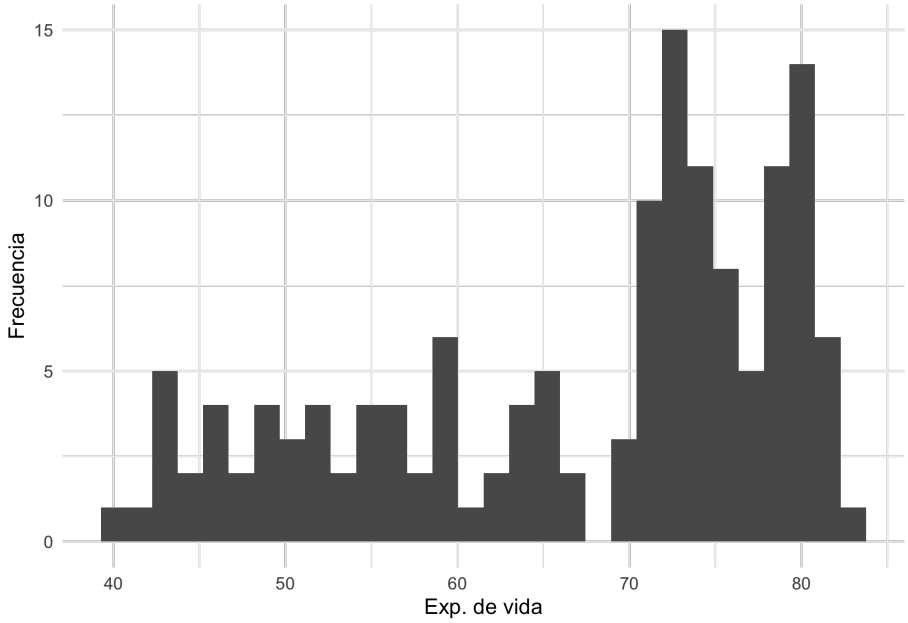

Fuente: Datos del paquete gapminder.

Nota que en el código incluimos en la capa de **Escalas** la función **labs()** que corresponde a las etiquetas en inglés. Esta función nos permite ponerle nombres a los ejes, título (argumento **title**) y subtítulo (argumento **subtitle**), entre otras etiquetas.

La Figura 3.2 muestra un histograma en color gris; color que es el valor por defecto de esta función. Si quisieras cambiar el color del histograma[3], lo podemos hacer con el argumento **fill**. Por ejemplo, corre estas líneas de código y obtendrás un histograma de color azul claro:

```
# Histograma de colo azul claro
gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = lifeExp)) +
    geom_histogram(fill = "lightblue") +
    labs( y="Frecuencia",
          x="Exp. de vida") +
    theme_minimal()
```

Si quieres ajustar otros aspectos del histograma, como el número de clases (grupos), puedes emplear los diferentes argumentos de esta función. Recuerda que buscar ayuda sobre una función es muy fácil.

3.2 Gráfico de barras

Los gráficos de barras permiten visualizar la distribución de una variable cualitativa; es decir, variables de clase **character** o **factor**. Este gráfico muestra con barras cuál es la frecuencia con que se observa cada uno de los posibles valores de la variable cualitativa. Este tipo de gráficos se puede construir con la función **geom_bar()**.

Por ejemplo, consideremos la variable `continent` que es un factor con cinco posibles valores. Visualicemos cómo es la distribución de países por continente en los datos de *gapminder* para el 2007. Es decir, contemos cuántas veces se repite cada continente en los datos de 2007. Esto lo podemos hacer con el siguiente código:

```
# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = continent)) +
    geom_bar(fill = "royalblue4") +
    labs( y="Frecuencia",
          x="Continente") +
    theme_minimal()
```

Figura 3.3. Distribución de los países por continente disponibles en los datos de gapminder para 2007

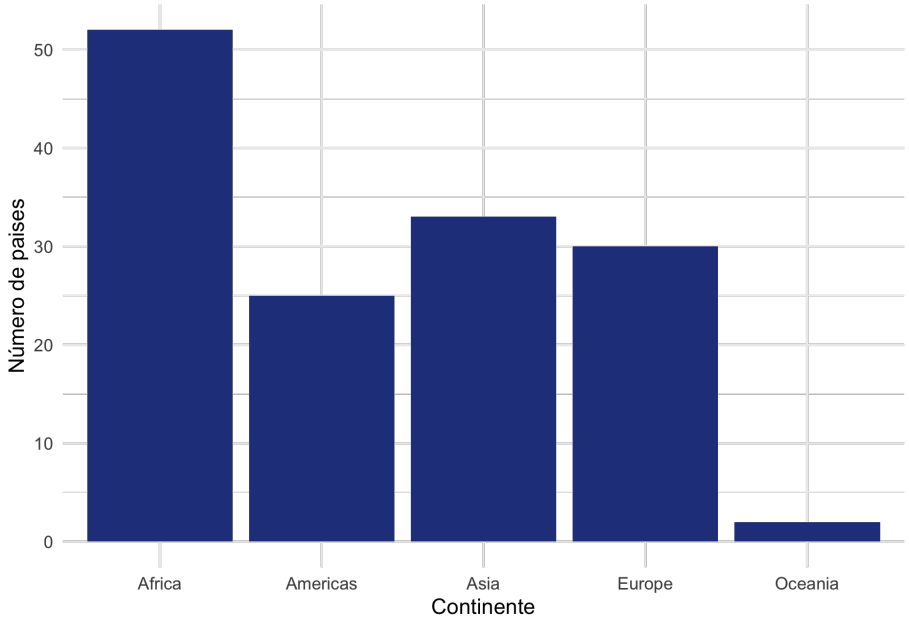

Fuente: Datos del paquete gapminder.

Recuerda que existen muchos más parámetros en estas funciones de la geometría que pueden ayudar a mejorar tu visualización. Es importante que mires en la ayuda todas las opciones que tienes.

La misma información anterior puede mostrarse de manera relativa (como porcentaje de todos los países) y no de manera absoluta (el número de países por continente). Este gráfico se conoce como un **gráfico de barras de porcentajes**. Esto lo podemos hacer de varias formas. Una forma es crear una base de datos con una columna que tenga el nombre del continente y otra con el porcentaje de países que el respectivo continente representa. Otra forma es modificar el código anterior, para calcular dicho porcentaje directamente en la función.

Por ejemplo, intenta evaluando el siguiente código:

```
gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = continent,
             y=100 * (..count..)/sum(..count..))) +
  geom_bar( fill = "royalblue4") +
  labs( y="%",
        x="Continente") +
  theme_minimal()
```

Mira con cuidado cómo se creó la variable **y** empleando **..count..**. Esta función cuenta la variable **x** para cada uno de los factores de esta.

3.3 Boxplot

Los **Boxplot** son conocidos como diagrama de cajas y bigotes o diagrama de cajas. Estos gráficos requieren de una audiencia con una formación en estadística para poder transmitir bien los mensajes poderosos que revelan. En tus cursos de estadística con seguridad estudiaste o estudiarás esta visualización. Por ahora recordemos que esta visualización permite observar el primer, segundo y tercer cuartil, la distancia intercuartílica y la existencia o no de datos atípicos. La Figura 3.4 te permitirá recordar la interpretación de este gráfico.

Este gráfico es muy empleado para comparar la distribución de una variable cuantitativa para los diferentes valores posibles de una variable cualitativa. Típicamente, la variable cualitativa se representa en el eje horizontal y en el eje vertical se representa la variable cuantitativa. La función que permite construir este gráfico es **geom_boxplot()**.

[3]Nota que esto es muy diferente a mapear una variable al color. Aquí solo estamos cambiando el color del histograma.

Figura 3.4. Elementos de un Boxplot

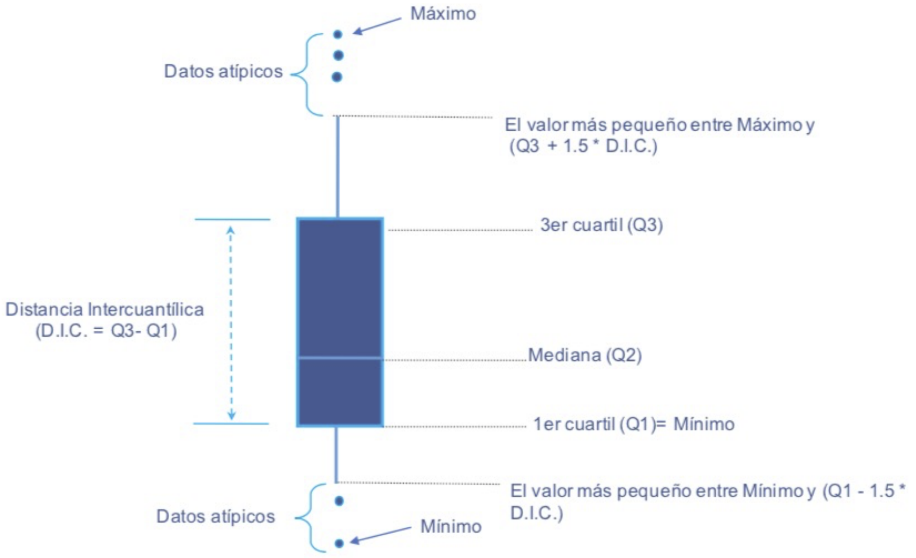

Fuente: Elaboración propia.

Visualicemos la distribución de la esperanza de vida al nacer por continente para el año 2007. Esto lo podemos hacer de la siguiente manera:

```
# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = continent, y = lifeExp)) +
    geom_boxplot(fill = "lightblue",
                 col = "royalblue4" ) +
    labs( y="Esperanza de vida al nacer",
          x="Continente") +
    theme_minimal()
```

3.4 Comentarios finales

Antes de continuar con las capas de ***Geometría*** que permiten mostrar evolución de una o más variables, es importante anotar que existen

Figura 3.5. Boxplot de la esperanza de vida al nacer por continente para 2007.

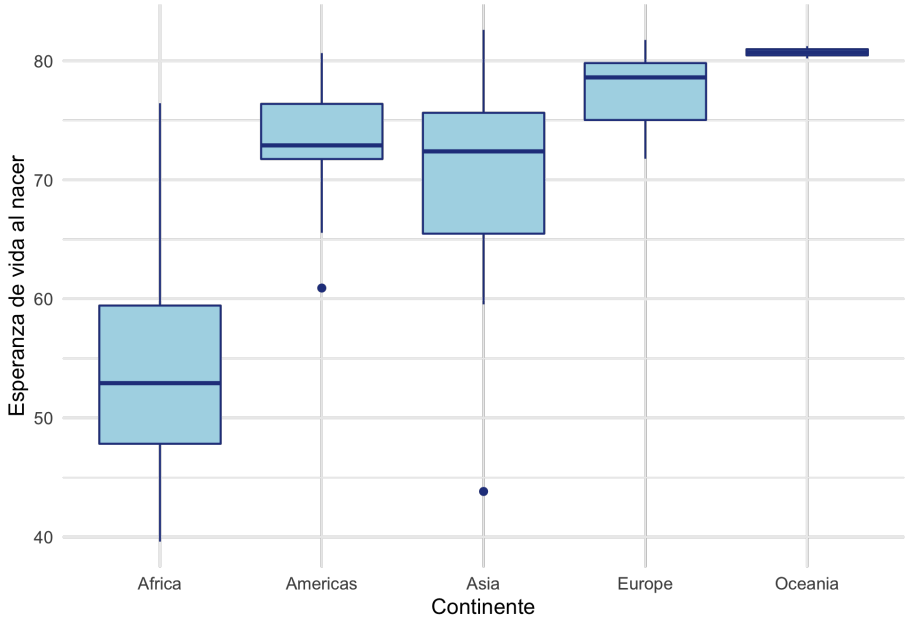

Fuente: Elaboración propia.

otras visualizaciones no tan comunes para mostrar distribución. Por ejemplo, está el gráfico de densidad, diagrama de violines[4], los gráficos de donas, los gráficos de waffles, los gráficos de bombones, los treemaps (como la Figura 1.4), los mapas de calor, los diagramas de Sankey y las nubes de palabras[5]. Si te interesa conocer más de estas visualizaciones puedes encontrar una amplia documentación en línea mantenida por la comunidad de usuarios de R y *ggplot2*. Ya conoces la lógica y la gramática que emplea este paquete, con seguridad será muy sencillo entender y modificar los códigos que encuentres disponibles en línea. Y no olvides compartir los códigos que creas de utilidad para los miembros de la comunidad.

[4]Si quieres conocer sobre los diagramas de violines, puedes ver una breve introducción en el siguiente enlace: https://bit.ly/3Jc71YC.

[5]Si quieres conocer sobre las nubes de palabras, puedes ver una breve introducción en el siguiente enlace: https://bit.ly/3HO46Fa.

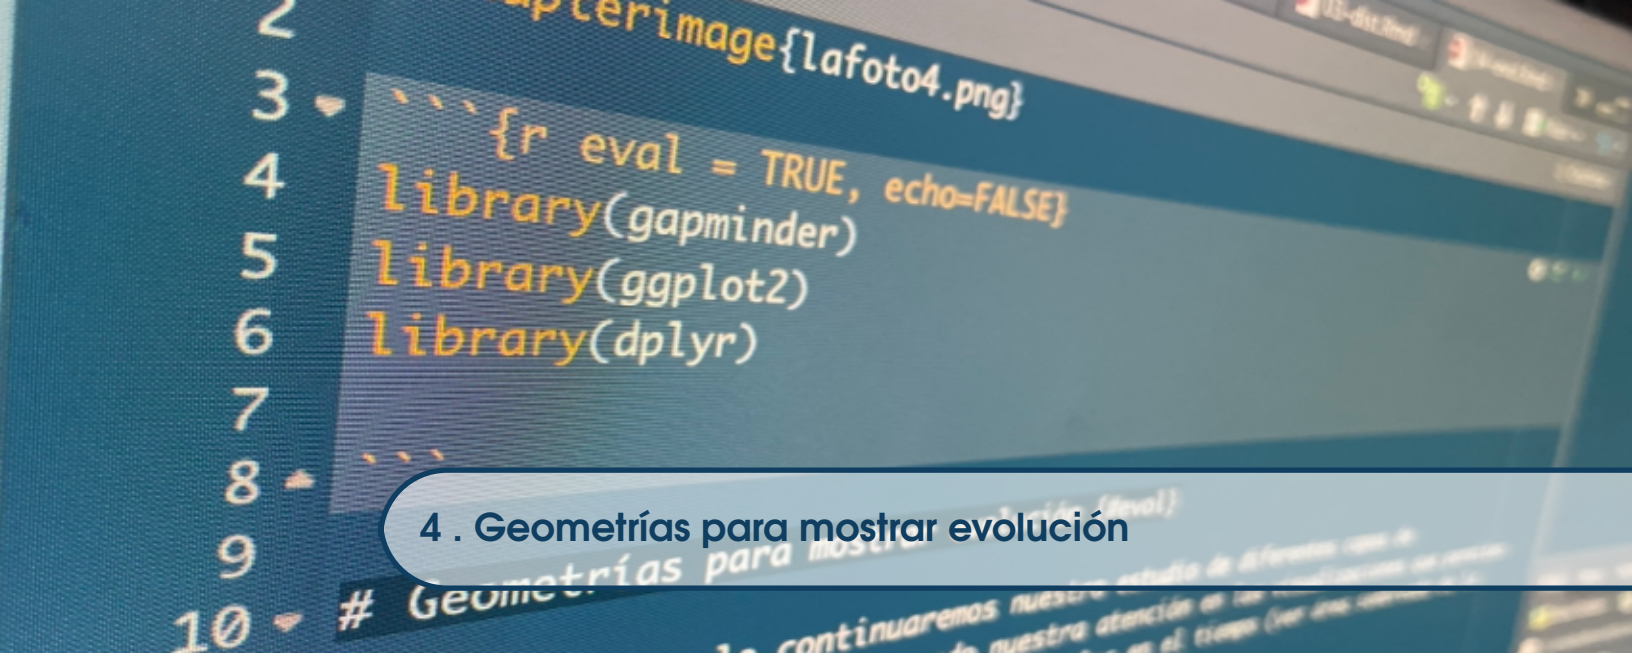

4 . Geometrías para mostrar evolución

En este capítulo continuaremos nuestro estudio de diferentes capas de ***Geometría***, concentrando nuestra atención en las visualizaciones que permiten mostrar evolución de una o más variables en el tiempo (ver área sombreada de la Figura 4.1).

Figura 4.1. Tipos de gráficos más comunes según lo que se desea comunicar y la clase de variable

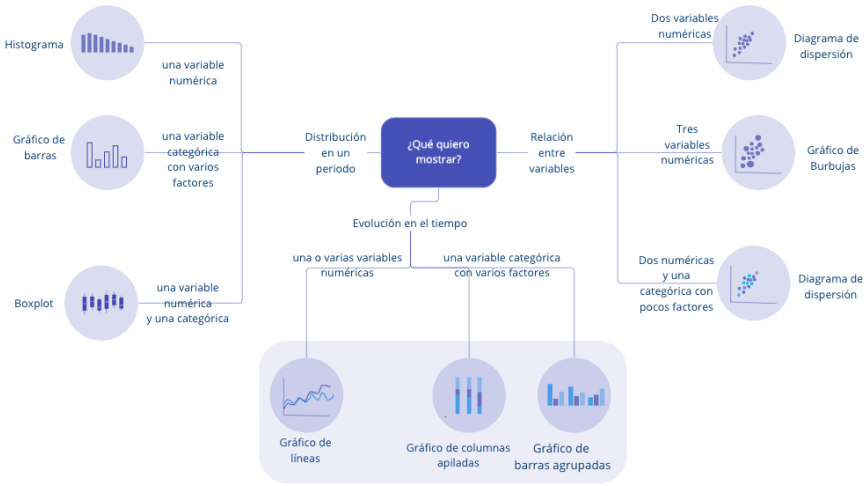

Fuente: Adaptación de Alonso y González (2012).

Los gráficos más comunes para mostrar evolución en el tiempo de una o más variables son:

- **Gráficos de líneas**
- **Gráficos de barras agrupadas**
- **Gráfico de columnas apiladas** o barras apiladas.

Al igual que en los capítulos anteriores, emplearemos en nuestros ejemplos los datos del objeto `gapminder` del paquete del mismo nombre.

4.1 Gráfico de líneas

Los gráficos de líneas son apropiados para visualizar el comportamiento histórico de una o más variables de clase **numeric** (variable cuantitativa continua) e **integer** (variable cuantitativa discreta). También nos permiten comparar el comportamiento en el tiempo de dos o más variables.

Estos gráficos reportan en el eje horizontal el período de tiempo (años, trimestres, meses o días según sea el caso) y en el eje vertical la variable de interés. Para cada periodo se identifica el correspondiente valor de la variable y todos los puntos se unen con líneas rectas. De ahí su nombre de gráfico de líneas. La función **geom_line()** permite construir este tipo de visulizaciones.

Por ejemplo, grafiquemos la evolución del PIB percápita de Colombia. En este caso recuerda que en el eje horizontal tendremos el año (**x = year**) y en le eje vertical tendremos el PIB percápita (**y =gdpPercap**). Entonces, primero filtramos los datos para Colombia y los pasamos a la capa de ***Datos***. Posteriormente, agregamos la capa de ***Aesthetics*** y finalmente la capa de ***Geometría*** con la función **geom_line()**. Agregamos una capa de **Escalas** para poner las etiquetas y una de **Tema** para mejorar la apariencia.

```
# cargamos los paquetes
library(ggplot2)
library(dplyr)
library(gapminder)

# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
   filter(country == "Colombia") %>%
    ggplot( aes(x = year, y =gdpPercap)) +
    geom_line() +
    labs( y="PIB percápita ($US)",
```

```
          x="Año") +
   theme_minimal()
```

Figura 4.2. Evolución del PIB percápita de Colombia (1952 - 2007) (datos cada 5 años)

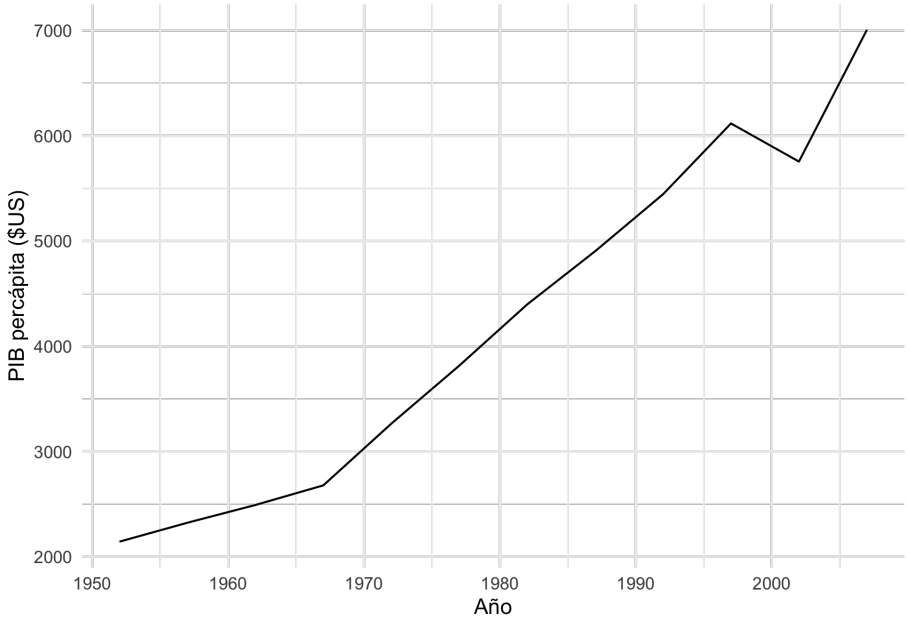

Fuente: Datos del paquete gapminder.

La Figura 4.2 presenta la evolución del PIB percápita de Colombia. En algunas ocasiones también queremos incluir otros países para además comparar la evolución en el tiempo entre países. Esto lo podemos hacer rápidamente. En este caso, dada la estructura de los datos, podemos incluir la variable país de clase **factor** en el color en la capa ***Aesthetics***.

Por ejemplo, grafiquemos la evolución del PIB percápita de los países de la Alianza del Pacífico (Colombia, Chile, Perú y México). Esto lo podemos hacer con el siguiente código:

```
# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
   filter(country %in% c("Colombia", "Peru", "Chile", "Mexico")) %>%
```

```
ggplot( aes(x = year, y =gdpPercap, color = country)) +
 geom_line() +
 labs( y="PIB percápita ($US)",
       x="Año", color = "País") +
 theme_minimal()
```

Figura 4.3. Evolución del PIB percápita de los países de la Alianza del Pacífico (1952 - 2007) (datos cada 5 años).

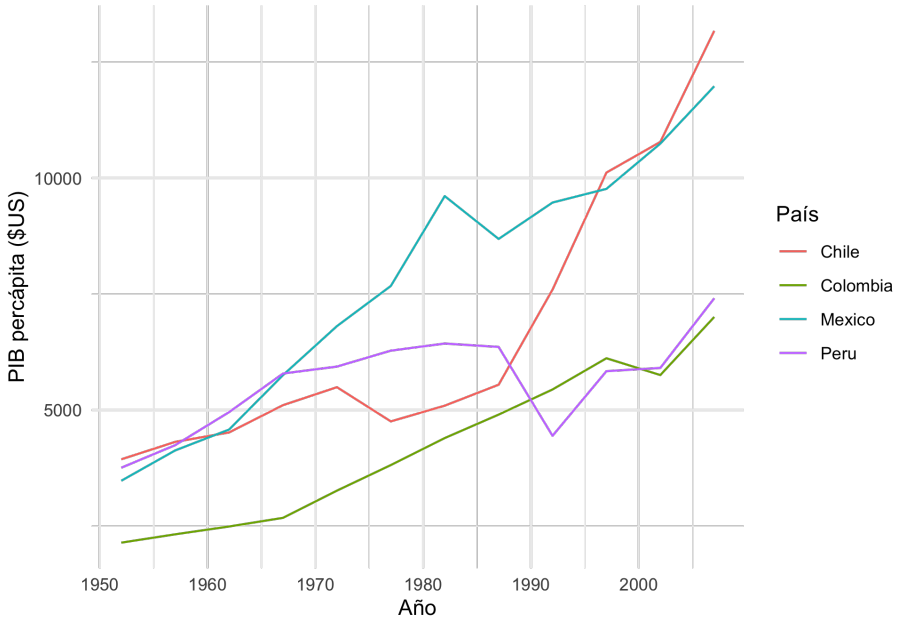

Fuente: Datos del paquete gapminder.

La Figura 4.3 nos permite ver la evolución en el tiempo del PIB percápita de los cuatro países. Esta tal vez es una de las visualizaciones más populares.

4.2 Barras agrupadas

Las barras agrupadas permiten comparar la evolución de la composición en el tiempo de una variable cualitativa de clase **factor**. Intuitivamente, esta visualización es un gráfico de barras (ver Sección 3.2) reproducido en diferentes periodos. Es decir, permite representar cómo cambia en el tiempo la participación porcentual en el total de cada uno de los posibles valores de la variable cualitativa. Típicamente, en el eje horizontal tendremos los períodos y en el eje vertical mediremos la participación porcentual de cada uno de los factores. El gráfico de barras agrupadas también lo podemos construir con la función **geom_bar()**. La diferencia en este caso es que tendremos que especificar qué variable se mapea al eje horizontal y cuál al vertical.

En la Sección 3.2 construimos un gráfico de barras (ver Figura 3.3) para la distribución de los países por continente disponibles en los datos del paquete *gapminder*. Eso lo realizamos para el año 2007. En esta oportunidad nos gustaría tener el mismo gráfico (en porcentaje) pero para todos los años que hacen parte del objeto *gapminder*. Para construir el gráfico necesitamos contar con un objeto de datos que tenga una columna con el número de países por continente (o la participación en el total de países) por año. En esta ocasión, por razones pedagógicas, separemos la preparación de la base de datos de la construcción de la visualización.

Los datos para nuestra visualización se pueden construir con el siguiente código[1]:

```
d1 <- gapminder %>%
  # se agrupan los casos por año y continente
  group_by(year, continent) %>%
  # se cuentan los países por cada continente, para cada año
  # frecuencia
  summarise( paises = n()) %>%
  # se crea la nueva variable con la frecuencia relativa
  mutate(Prop_paises = 100 * paises / sum(paises))

glimpse(d1)
```

```
## Rows: 60
## Columns: 4
## Groups: year [12]
## $ year        <int> 1952, 1952, 1952, 1952, 1952, 1957, 1957,~
## $ continent   <fct> Africa, Americas, Asia, Europe, Oceania, ~
```

[1] Asegúrate que entiendes cómo se resumen las observaciones y se crean las variables. Si necesitas ayuda, puedes ver el Capítulo 2 de Alonso (2022).

```
## $ paises      <int> 52, 25, 33, 30, 2, 52, 25, 33, 30, 2, 52,~
## $ Prop_paises <dbl> 36.619718, 17.605634, 23.239437, 21.12676~
```

Ahora, podemos crear la visualización empleando en la capa de ***Datos*** el objeto `d1`. En la capa de ***Aesthetics*** podemos mapear los años al eje horizontal (**x = as.character(year)**)[2], en el eje vertical la participación porcentual de cada continente (**y = Prop_paises**) y el relleno de las barras corresponderá al respectivo continente (**fill = continent**). En la capa de ***Geometría*** emplearemos la función **geom_bar()**. Para esta visualización necesitamos dos argumentos. El primero es la posición de las barras que estarán una al lado de la otra. Para esto tendremos el siguiente argumento: **position = "dodge"**. El segundo argumento corresponde a qué estadística queremos que se represente en el eje vertical. Por defecto **geom_bar()** cuenta el número de casos en cada grupo y lo pone en el eje vertical (**stat="bin"**)[3]. En este caso queremos que se mapee al eje vertical los valores de una columna (**y = Prop_paises**). Esto lo logramos poniendo este argumento igual a **"identity"** (**stat = "identity"**).

```
ggplot(d1, aes(x = as.character(year), y = Prop_paises,
               fill = continent)) +
  geom_bar(position = "dodge", stat = "identity") +
  labs(y = "% del número de países total",
       x = "Año", fill = "Continente") +
  theme_minimal()
```

La Figura 4.4 muestra que no ha tenido cambio la participación de los continentes durante el periodo 1952-2007. Este gráfico en esta ocasión no es interesante, pero esto dependerá de la base de datos que tengas.

El gráfico de barras agrupadas también puede ser empleado para mostrar la evolución de una variable cuantitativa y una cualitativa. Por ejemplo, podemos ver cómo ha cambiado la participación en la población mundial de cada continente. Esto lo podemos hacer con el siguiente código que genera la Figura 4.5. Puedes observar que Asia es el continente más poblado y su participación ha venido creciendo levemente.

```
d2 <- gapminder %>%
      group_by(year, continent) %>%
      summarise( Poblacion = sum(pop)) %>%
      group_by(year) %>%
```

[2] Aquí estamos empleando un truco. Pasando los años como texto hace que aparezcan todos los años en el eje. Intenta mapear la variable año sin la transformación a texto (**x = year**) y verás que no aparecerán todos los años.

[3] Nota que esto fue lo que hicimos cuando creamos el gráfico de barras que se reporta en la Figura 3.3).

Figura 4.4. Evolución de la distribución de los países por continente disponibles en los datos de gapminder (1952 - 2007)

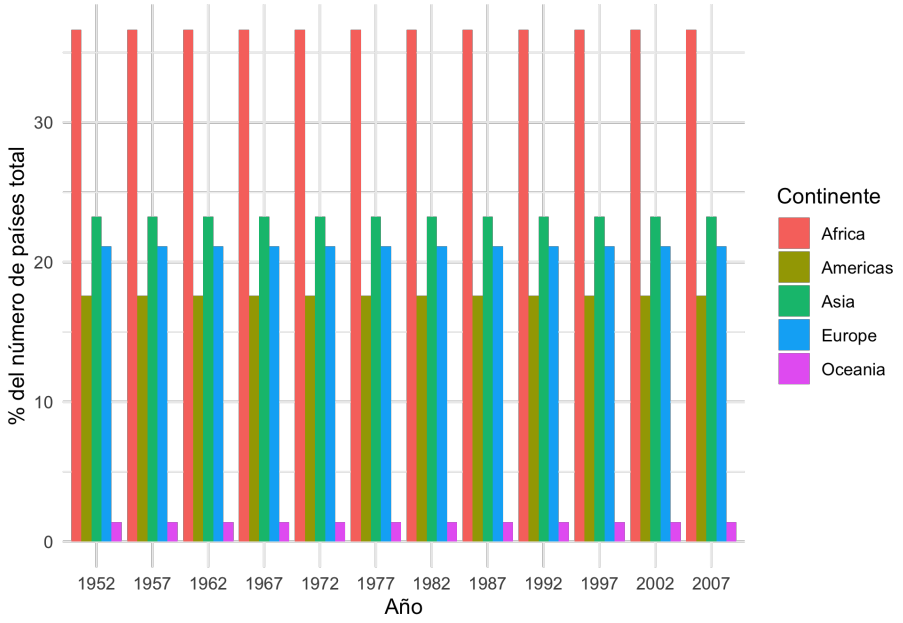

Fuente: Datos del paquete gapminder.

```
      mutate(Prop_Poblacion = 100 * Poblacion / sum(Poblacion))

ggplot(d2, aes(x = as.character(year),
               y = Prop_Poblacion, fill = continent))+
  geom_bar(position = "dodge", stat="identity")+
  labs(y = "% de la población mundial",
       x = "Año", fill = "Continente")+
  theme_minimal()
```

Figura 4.5. Evolución de la distribución de la población mundial por continente (1952 - 2007)

Fuente: Cálculos propios empleando datos del paquete gapminder.

4.3 Columnas apiladas

Otra alternativa a las barras agrupadas son las barras apiladas. En este caso, como su nombre lo implica, las barras están una encima de la otra. Esta visualización implica una leve modificación al código que genera las barras agrupadas, en el argumento de posición de la función **geom_bar()** empleamos **position = "stack"**. Intenta modificar el código para obtener las Figuras 4.6 y 4.7.

Figura 4.6. Evolución de la distribución de los países por continente disponibles en los datos de gapminder (1952 - 2007)

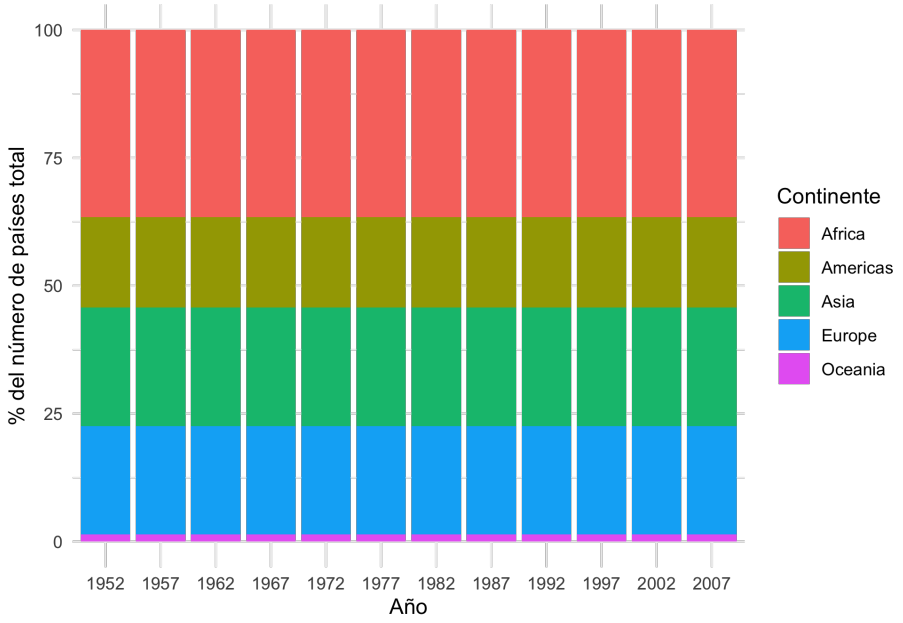

Fuente: Cálculos propios empleando datos del paquete gapminder.

Figura 4.7. Evolución de la distribución de la población mundial por continente (1952 - 2007)

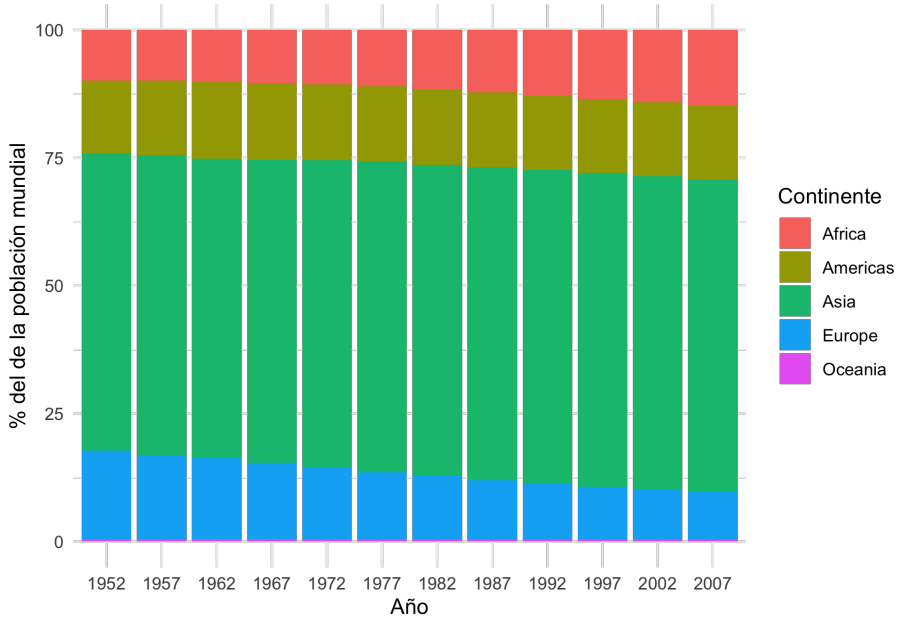

Fuente: Cálculos propios empleando datos del paquete gapminder.

4.4 Comentarios finales

En este capítulo evidenciamos que a veces crear visualizaciones implica transformar un objeto con datos para tener el conjunto de estos mismos de la manera más adecuada y así, poder generar la visualización. Es así como el paquete *dplyr* (Wickham et al., 2021) y el paquete *ggplot2* presentan una integración ideal para facilitar el flujo de trabajo. Si aún no dominas el paquete *dplyr* puedes ver Alonso (2022). Con seguridad si dominas estos dos paquetes, podrás generar visualizaciones de gran impacto en tu audiencia. Los dos paquetes te darán una gran versatilidad para mejorar la apariencia de tus visualizaciones. De hecho, en el Capítulo 6 discutiremos algunas estrategias que te serán muy útiles al momento de generar gráficos. Pero antes, estudiaremos las visualizaciones que permiten mostrar relación entre variables (Capítulo 5).

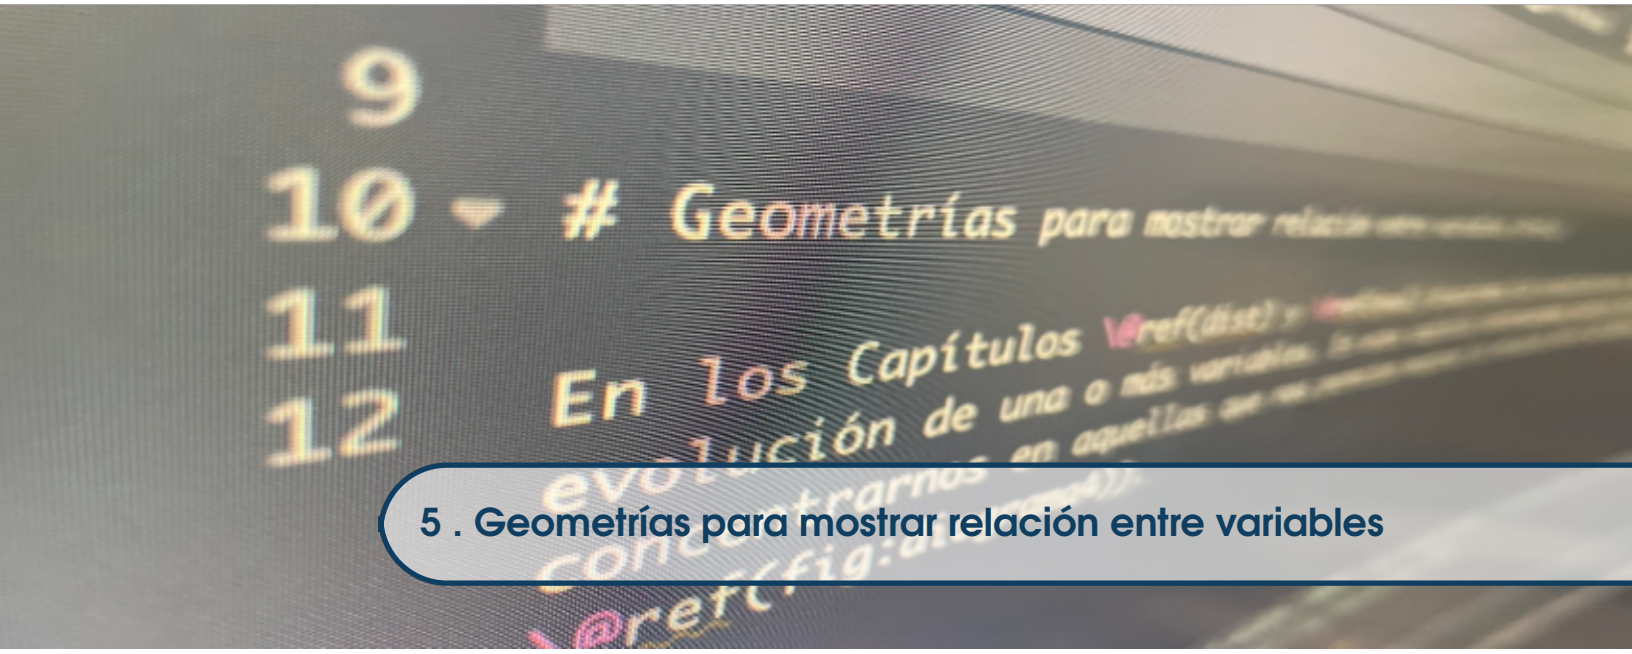

5 . Geometrías para mostrar relación entre variables

En los Capítulos 3 y 4 discutimos las visualizaciones más comunes para mostrar la distribución y la evolución de una o más variables. En este capítulo continuaremos nuestro estudio de diferentes capas de ***Geometría*** para concentrarnos en aquellas que nos permiten mostrar la relación entre variables (ver parte sombreada de la Figura 5.1).

Figura 5.1. Tipos de gráficos más comunes según lo que se desea comunicar y la clase de variable

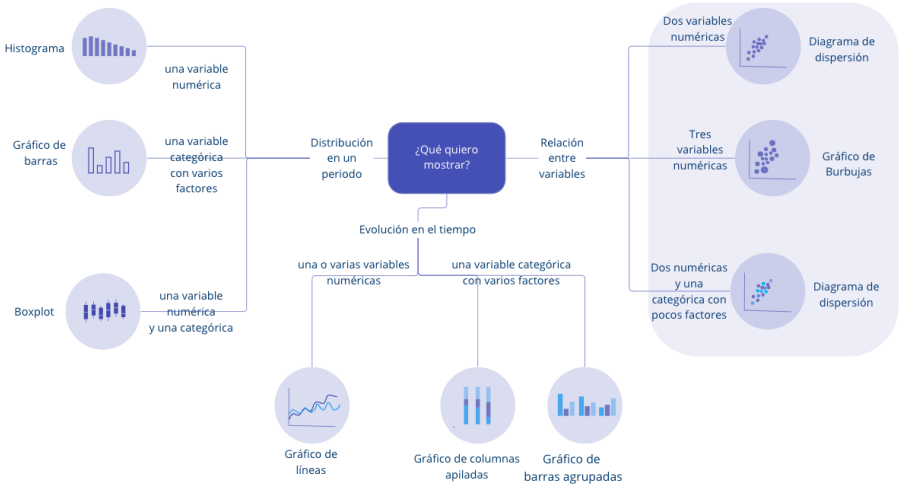

Fuente: Adaptación de Alonso y González (2012).

La gráfica más empleada para mostrar la relación entre dos variables es el diagrama de dispersión. Esta visualización es muy versátil y nos

permite incluir aún más variables si jugamos con el tamaño de los puntos (conocido como gráfico de burbujas), su color o su tamaño. En este capítulo nos concentraremos en este gráfico.

5.1 Diagrama de dispersión

Cuando se busca mostrar una relación entre dos variables numéricas, lo mejor es hacer uso de un diagrama de dispersión. En la Figura 5.2 se muestra un ejemplo de la relación entre la expectativa de vida y el PIB percápita para todos los países en 2007. Este fue el primer gráfico que aprendimos ha construir en el Capítulo 2.

Recuerda que este gráfico lo podemos generar con la función **geom_point()** empleando el siguiente código:

```
# cargamos los paquetes
library(ggplot2)
library(dplyr)
library(gapminder)

# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos

gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = gdpPercap, y = lifeExp)) +
  geom_point() +
  labs(  x="PIB percápita", y="Esp. de vida") +
  theme_minimal()
```

Es importante anotar que en algunas ocasiones se pueden tener muchos puntos que se superponen (en inglés *over-plotting*) y se tapan entre sí cuando se mapean. En esos casos nos podemos dar unas libertades "artísticas" añadiendo una pequeña cantidad de variación aleatoria a la ubicación de cada punto. De esta manera, los puntos no se sobreponen y la visualización nos permitirá endender mejor los datos. Esto se logra con la función **geom_jitter()** . Por ejemplo, en el panel a de la Figura 5.3 se muestra un diagrama de dispersión con todos los datos de *gapminder* con el año en el eje horizontal y la esperanza de vida al nacer en el vertical empleando la función **geom_point()**. Observa que los puntos se ven sobre puestos. Esta visaulización es apenas natural (asegúrate que te queda claro el porqué obtenemos esta visualización).

Figura 5.2. PIB percápita y expectativa de vida al nacer por país (2007).

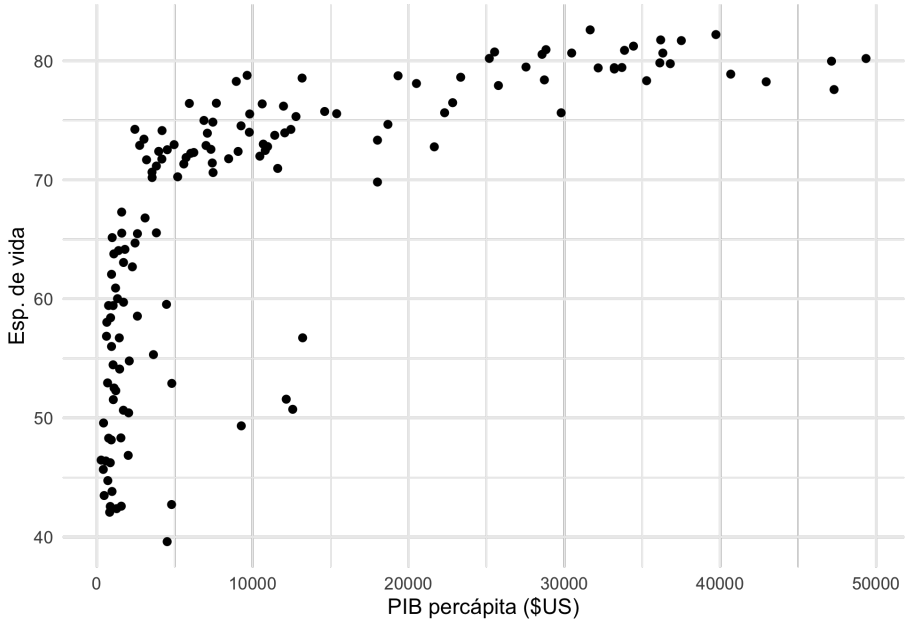

Fuente: Datos del paquete gapminder.

Figura 5.3. Relación entre la expectativa de vida al nacer y el año.

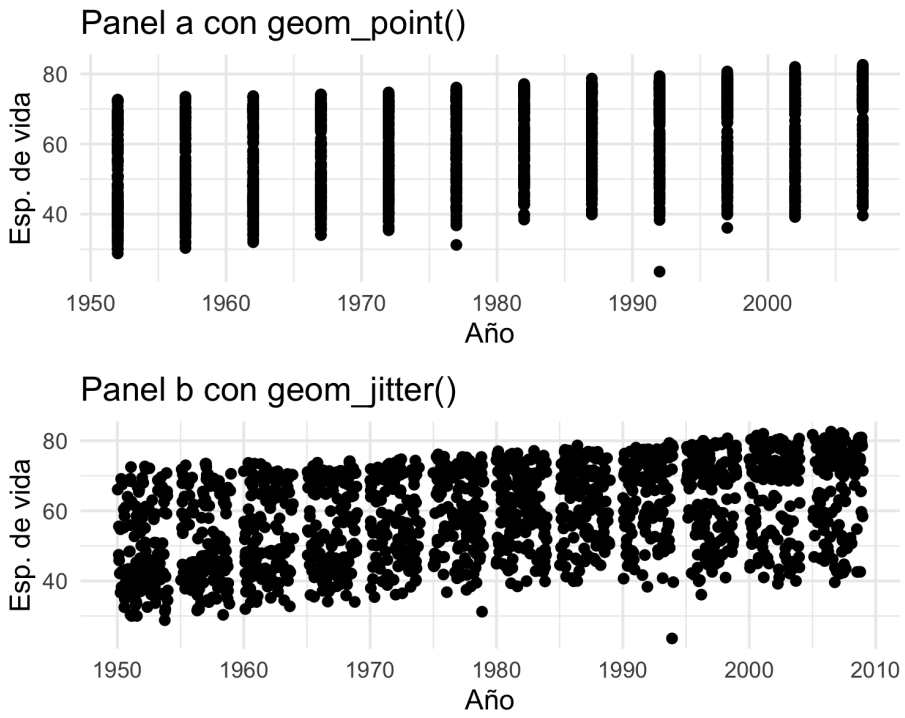

Fuente: Datos del paquete gapminder.

En el panel b de la Figura 5.3 se muestran los mismo datos, pero tomándonos una libertad "artística" de mover un poco horizontal y verticalmente los puntos para que no se sobrepongan. Esta vizualización fue creada con la función **geom_jitter()** . Si bien, esta visualización no es exacta, brinda una mejor idea de cómo se relacionan el año y la esperanza de vida al nacer. Del contexto de tu visualización, podrás tomar la decisión de si tiene o no sentido emplear la función **geom_jitter()** en vez de **geom_point()**. La Figura 5.3 fue creada con el siguiente código:

```
# panel a
ggplot(gapminder, aes(x = year, y = lifeExp)) +
                geom_point() +
                labs(title = "Panel a con geom_point()",
                     x="Año", y="Esp. de vida") +
               theme_minimal()
# panel b
ggplot(gapminder, aes(x = year, y = lifeExp)) +
                geom_jitter() +
                labs(title = "Panel b con geom_jitter()",
                     x="Año", y="Esp. de vida") +
               theme_minimal()
```

5.2 Gráfico de burbujas

En algunas situaciones será interesante incluir una tercera variable numérica a nuestra visualización. El diagrama de dispersión permite una tercera variable numérica si la mapeamos al tamaño del punto. Esto tendrá una apariencia de burbujas, por eso el nombre de esta visualización. En general será mucho más clara y transmitirá mejor el mensaje que emplear gráficas en tres dimensiones.

Generarla es muy sencillo, tendremos que mapear nuestra tercera variable numérica al argumento **size** de la capa **Aesthetic**. La Figura 5.4 presenta un gráfico de burbujas construido con el siguiente código:

```
gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = gdpPercap, y = lifeExp,
             size = pop)) +
  geom_point(col = "royalblue2") +
  labs(  x="PIB percápita ($US)",
         y="Esp. de vida",
         size="Población") +
  theme_minimal()
```

Figura 5.4. PIB percápita, expectativa de vida al nacer y población por país (2007)

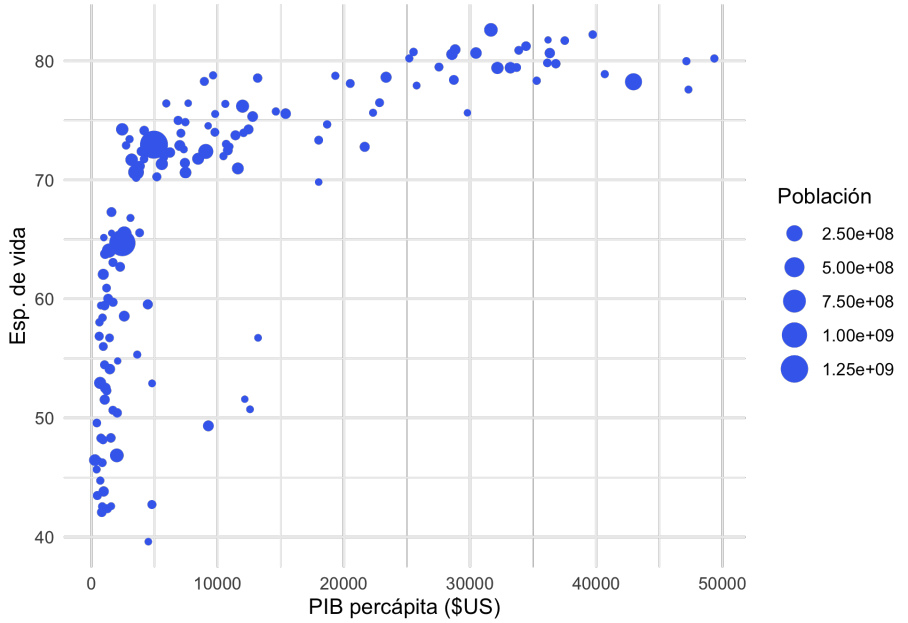

Fuente: Datos del paquete gapminder.

5.3 Diagrama de dispersión y variables cualitativas

También podemos incluir variables cualitativas en un diagrama de dispersión. Esto lo podemos hacer mapeando la variable cualitativa al color de los puntos. Esto nos da bastante flexibilidad en nuestros gráficos. Es más, podríamos incluir una quinta variable en nuestro diagrama de dispersión si mapeamos una variable cualitativa a la forma del punto. Pero tenemos que ser cuidadosos de no saturar nuestra visualización. Típicamente en las visualizaciones "menos es más".

Por ejemplo, incluyamos la variable continente a nuestro gráfico de burbujas. El siguiente código permite generar la Figura 5.5.

```
gapminder %>%
  filter(year == 2007) %>%
  ggplot(aes(x = gdpPercap, y = lifeExp,
             size = pop, col = continent )) +
  geom_point() +
  labs(  x = "PIB percápita ($US)",
         y = "Esp. de vida",
         size = "Población",
         col = "Continente") +
  theme_minimal()
```

5.4 Comentarios finales

En este capítulo hemos trabajado tres visualizaciones más, con esto completamos 9 tipos de visualizaciones que nos permiten mostrar distribución, evolución y relación entre variables. Ya tienes en tu caja de herramientas estas poderosas funciones que te permitirán mostrar conjuntos de datos grandes o pequeños. En el Capítulo 6 discutiremos unas estrategias para mejorar la apariencia de tus visualizaciones.

Figura 5.5. PIB percápita, expectativa de vida al nacer y población por país (2007)

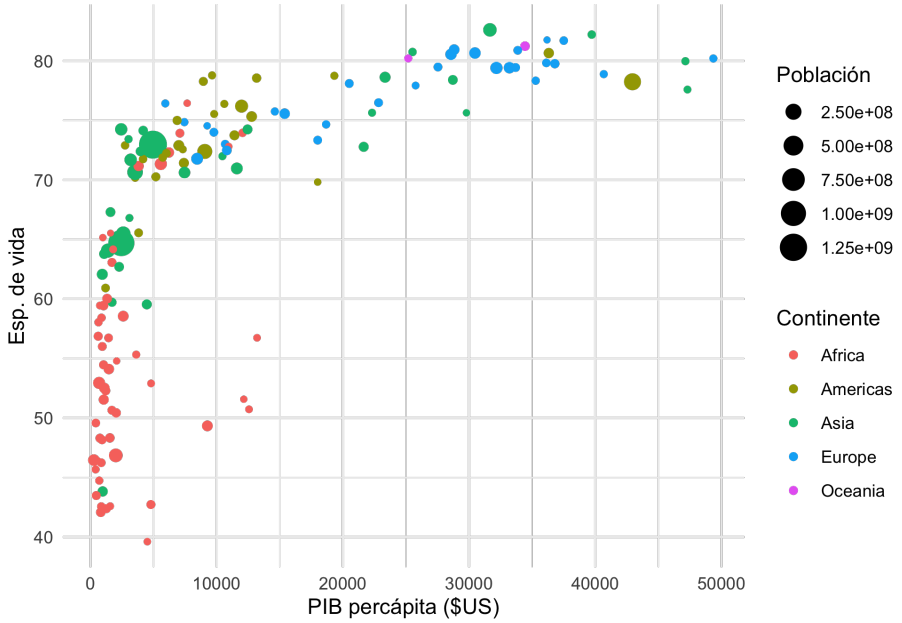

Fuente: Datos del paquete gapminder.

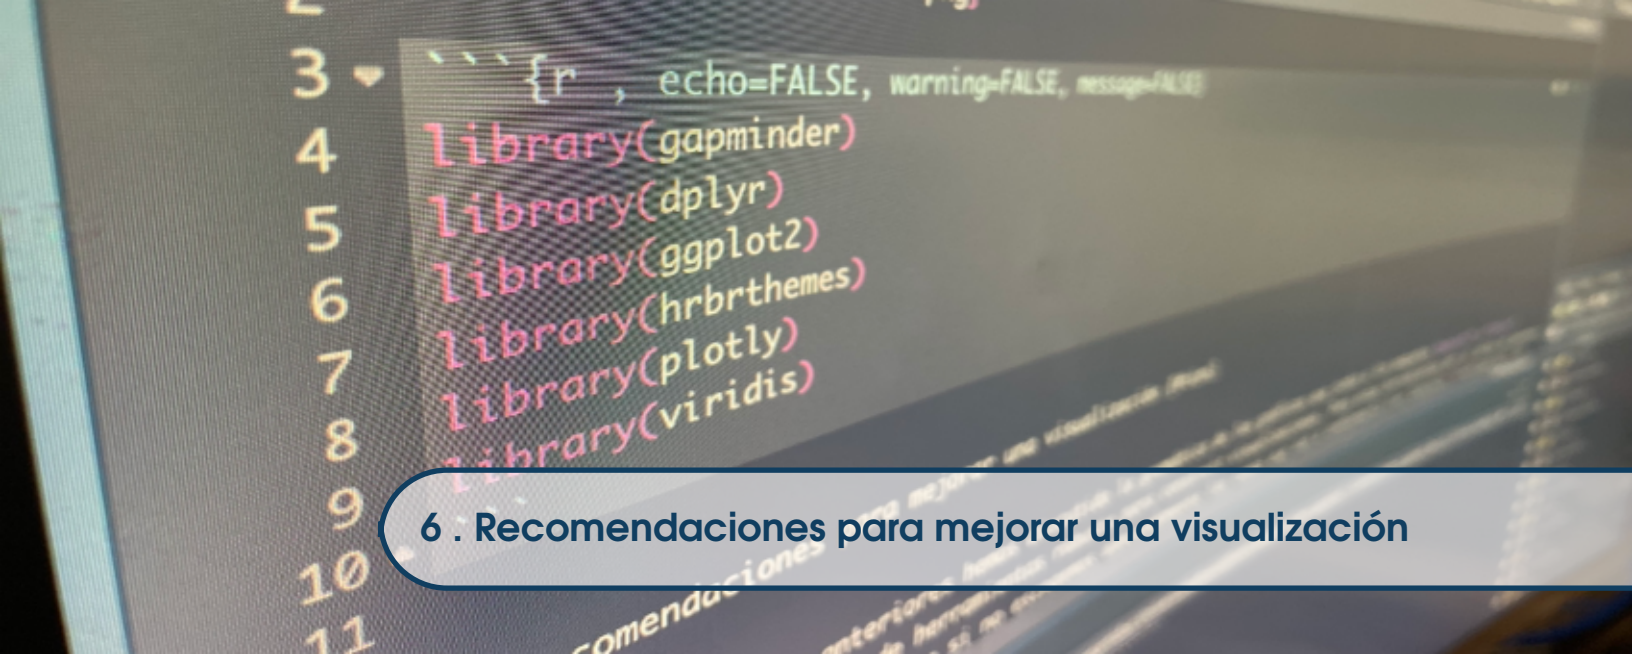

6 . Recomendaciones para mejorar una visualización

En los capítulos anteriores hemos discutido la gramática de los gráficos que junto a los paquetes *ggplot2* y *dplyr* constituyen una caja de herramientas robusta para construir visualizaciones. Pero estas herramientas por sí solas no generan una visualización efectiva si no escogemos adecuadamente las capas que van a conformarla (ver Capítulo 2). En especial en los Capítulos 3, 4 y 5 se discutió la importancia de seleccionar el tipo de gráfico (capa de ***Geometría***) de acuerdo a lo que queremos mostrar y a la clase de variables que tenemos.

Hasta aquí nos hemos concentrado más en la parte técnica de cómo generar un gráfico, pero es innegable que una buena visualización implica también unas nociones de estética y por supuesto un mensaje que comunicar. De hecho, una visualización busca contar una historia y para que se cumpla ese objetivo debemos visualizar nuestros datos de la manera más estética y fiel a ellos.

Como se mencionaba con anterioridad, crear una buena visualización no es tarea fácil. Implica ensayo y error. Es un proceso iterativo; difícilmente lograremos la mejor al primer intento.

Para empezar la construcción de una visualización siempre deberíamos responder por lo menos las siguientes tres preguntas:

- ¿Cuál es el mensaje que queremos comunicar?
- ¿Qué variables de las disponibles permiten comunicar el mensaje?
- ¿Quién es mi audiencia?

Estas preguntas nos ayudan a determinar las capas de la visualización. Y al momento de construir nuestras visualizaciones deberíamos tener en cuenta que nuestros gráficos deberán siempre:

- **Mostrar fielmente los datos**. Esto ayuda a que las decisiones que

puedan ser tomadas con las visualizaciones no estén sesgadas a datos distorsionados.
- **Reducir las distracciones**. Es decir no incluir elementos innecesarios en nuestras visualizaciones. En la construcción de una buena visualización, ¡menos es más!
- **Agregar texto cuando sea posible**. El texto facilita la comunicación y nos permite enfatizar nuestro mensaje.

En este capítulo encontrarás cuatro recomendaciones prácticas que te permitirán implementar estos tres elementos, mejorando tus visualizaciones de manera rápida y fácil al emplear *ggplot2*.

6.1 Ordena los datos

La visualización puede tener un mayor impacto ordenando los datos. La lectura de una visualización con datos ordenados es mucho más sencilla para la audiencia y esto termina por hacerla más simple y efectiva.

Por defecto, las visualizaciones que contienen una variable de clase **character** o **factor**, suelen ordenarse alfabéticamente. Por ejemplo, construyamos una visualización para el PIB percápita del 2007 de todos los países del continente americano. El siguiente código produce el correspondiente gráfico de barras (ver Figura 6.1):

```
# cargamos los paquetes
library(ggplot2)
library(dplyr)
library(gapminder)

# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos
gapminder %>%
  filter(year == 2007, continent == c("Americas")) %>%
  ggplot( aes(x=country, y=gdpPercap) ) +
    geom_bar(stat="identity") +
    labs(x = "país", y = "PIB percápita ($US)") +
    theme_minimal()
```

La Figura 6.1 presenta los datos, pero el mensaje no es muy claro. Podemos mejorar sustancialmente la visualización si hacemos dos cosas. Primero, volteemos los ejes en la capa de **Coordenadas** con la función **coord_flip()** . Esto le dará más espacio a los nombres de los países. Y lo

Figura 6.1. Gráfico no ordenado del PIB percápita para los países de América (2007)

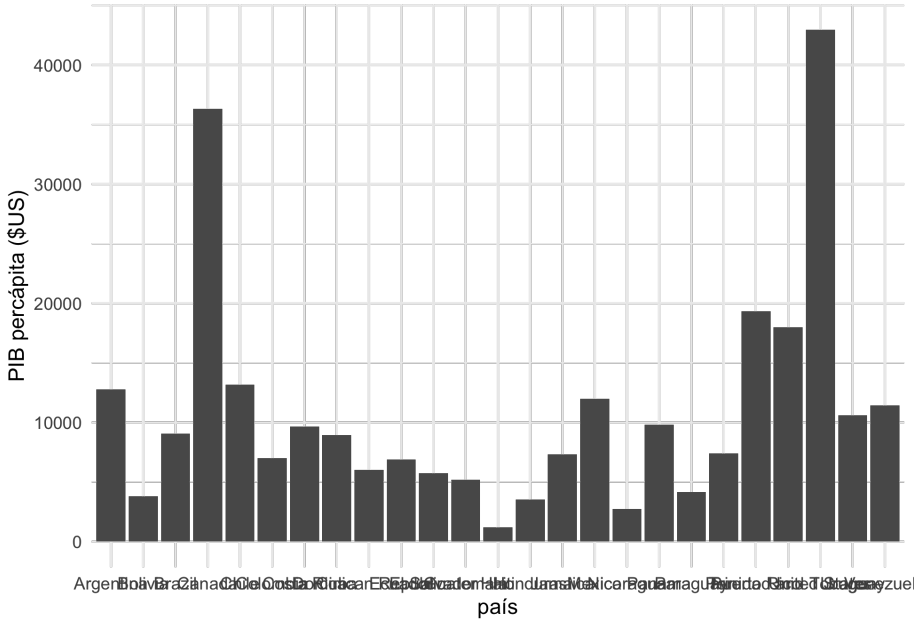

Fuente: Datos del paquete gapminder.

segundo que podemos hacer es ordenar los países por su PIB percápita[1]. El correspondiente código será:

```
# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos
gapminder %>%
  filter(year == 2007, continent == c("Americas")) %>%
  arrange(gdpPercap) %>%
  mutate(country=factor(country, country)) %>%
  ggplot( aes(x=country, y=gdpPercap) ) +
    geom_bar(stat="identity") +
    labs(x = "País", y = "PIB percápita ($US)") +
    coord_flip() +
    theme_minimal()
```

Figura 6.2. Gráfico ordenado del PIB percápita para los países de América (2007)

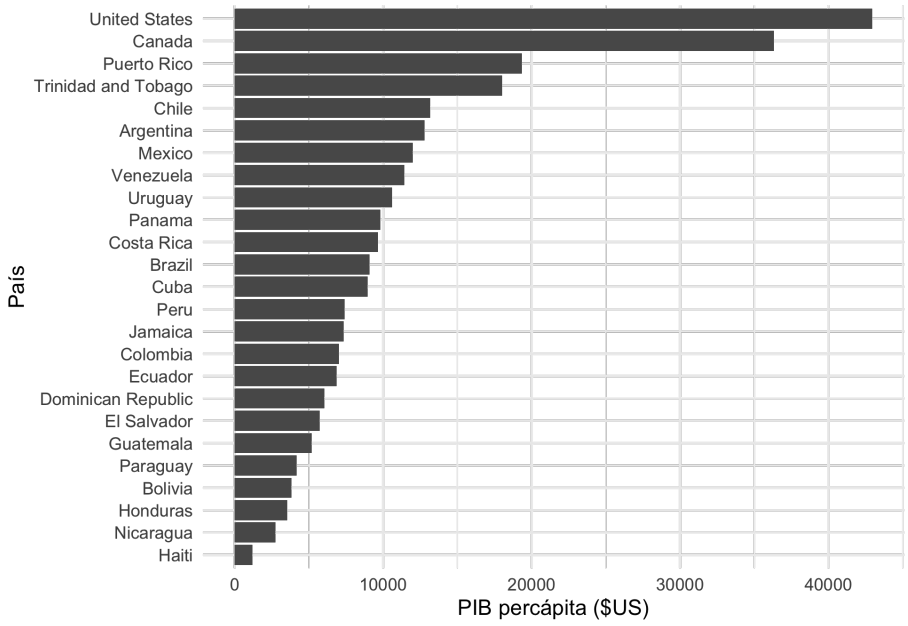

Fuente: Datos del paquete gapminder.

En la Figura 6.2 se ven mucho más claros los datos y permite su enten-

[1] Además, empleamos un "truco" con la variable país al convertirla en una variable de clase **factor**. ¡Intenta correr el código sin el "truco" y verás la diferencia!

dimiento más fácilmente.

6.2 Ten cuidado con los colores que no comunican

El uso de colores en las visualizaciones debe hacerse con mucho cuidado. Los colores al llamar la atención de la audiencia deben transmitir algo. Muchos colores pueden resultar engañosos si su uso no es el adecuado, como se muestra en la Figura 6.3, donde la cantidad de colores hace muy difícil la comparación entre categorías. Es más, los colores son redundantes, pues en el eje vertical ya tenemos el nombre de cada barra. El color no está comunicando nada. Estos colores están distorsionando el mensaje verdadero de la visualización.

```
# se emplea el operador pipe para
# pasar los datos y filtrar los
# datos
gapminder %>%
  filter(year == 2007, continent == c("Americas")) %>%
  arrange(gdpPercap) %>%
  mutate(country=factor(country, country)) %>%
  ggplot( aes(x=country, y=gdpPercap, fill=country) ) +
    geom_bar(stat="identity") +
    labs(x = "País", y = "PIB percápita ($US)",
         color = "País") +
    coord_flip() +
    theme_minimal() +
    theme(legend.position = "bottom")
```

Figura 6.3. Gráfico colores que no comunican

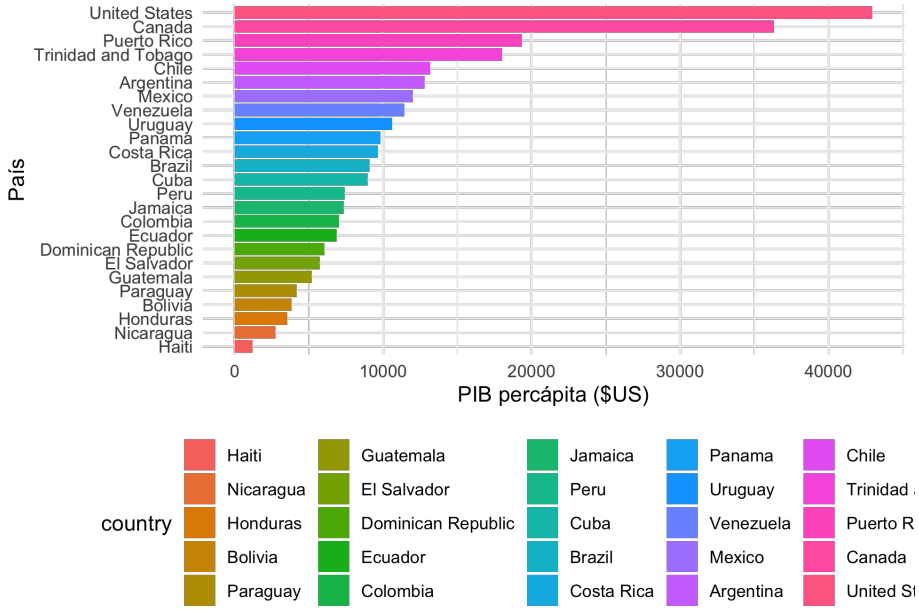

Fuente: Datos del paquete gapminder.

La Figura 6.3 se puede mejorar usando un solo color como en la Figura 6.2. Sin embargo, los colores sí se pueden emplear para comunicar un mensaje. Si por ejemplo queremos hacer énfasis en el dato de Colombia, podemos ayudarnos con el color. Los colores nos podrían ayudar para resaltar los datos para una sola categoría, como se muestra en la Figura 6.4.

Figura 6.4. Gráfico con color para resaltar

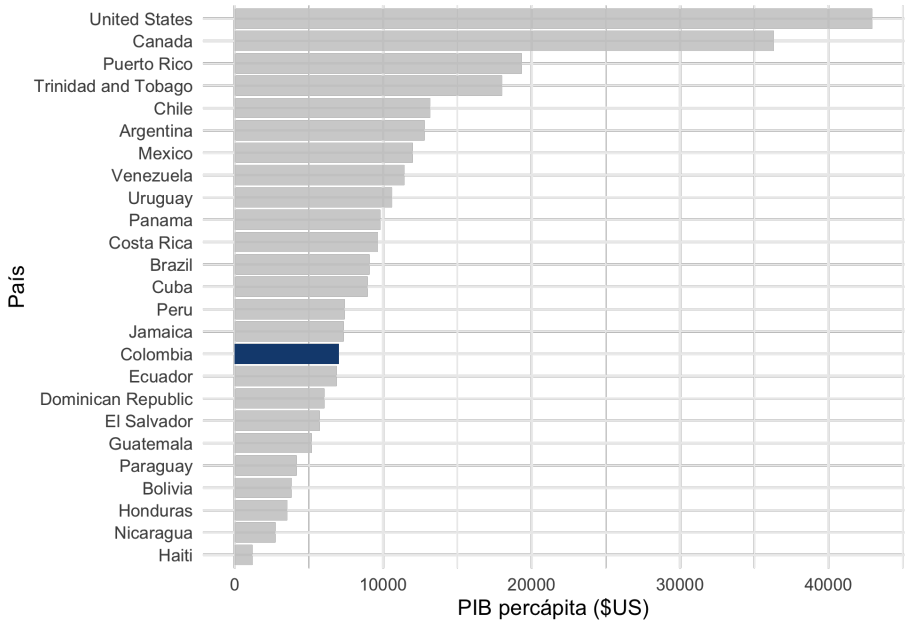

Fuente: Cálculos propios empleando datos del paquete gapminder.

El código que generó la Figura 6.4 es el siguiente. Mira con detalle la última línea del código. En este caso empleamos la función **gghighlight()** del paquete *gghighlight* (Yutani, 2020) que permite agregar la posibilidad de resaltar una sola barra.

```
library(gghighlight)
BLUE1 <- '#174A7E'

gapminder %>%
  filter(year == 2007, continent == c("Americas")) %>%
  arrange(gdpPercap) %>%
  mutate(country=factor(country, country)) %>%
  ggplot( aes(x=country, y=gdpPercap, fill=country) ) +
  geom_bar(stat="identity", fill = BLUE1) +
    labs(x = "País", y = "PIB percápita ($US)",
         color = "País") +
    coord_flip() +
    theme_minimal() +
    theme(legend.position = "bottom") +
  gghighlight(country == 'Colombia', use_direct_label = F)
```

6.3 Evita los gráficos *Spaghetti*

Los gráficos de líneas pueden ser confusos si contamos con muchas variables. Por ejemplo, en la Figura 6.5 es complicado seguir la evolución de una sola línea; incluso los colores de la leyenda son difíciles de identificar. Estos gráficos se conocen como gráficos *Spaghetti*, pues se parecen a un plato de Spaghetti donde es difícil identificar un solo *Spaghetti*.

Figura 6.5. Gráfico Spaghetti de la evolución del PIB percápita en los países de América (1955-2007)

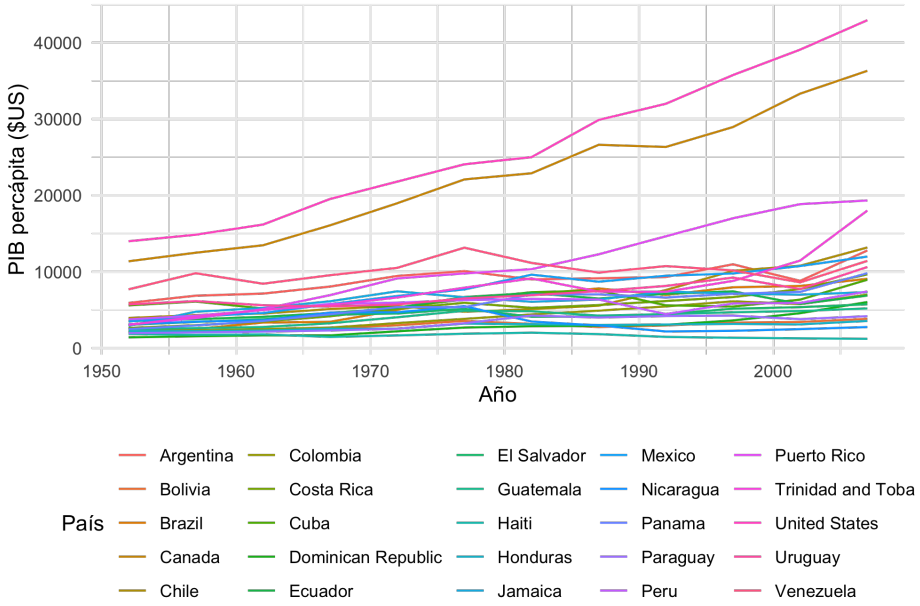

Fuente: Cálculos propios empleando datos del paquete gapminder.

El código que generó la Figura 6.5 es el siguiente (míralo detalladamente):

```
gapminder %>%
  filter(continent == c("Americas")) %>%
  ggplot( aes(x=year, y=gdpPercap,  color=country)) +
    geom_line() +
    labs(x = "Año", y = "PIB percápita ($US)",
         color = "País") +
    theme_minimal() +
    theme(legend.position = "bottom")
```

Ahora, supón que la historia que quieres contar tiene que ver con Colombia. En ese caso, la anterior visualización se puede mejorar empleando un color para resaltar los datos de Colombia (ver la Figura 6.6). Al resaltar la variable que se quiere enfatizar, se reducen las distracciones. Además podemos eliminar los colores de las demás leyendas. Y finalmente podemos incluir un texto para enfatizar el mensaje que queramos transmitir.

Figura 6.6. Evolución del PIB percápita en Colombia y otros países de Américа (1955-2007)

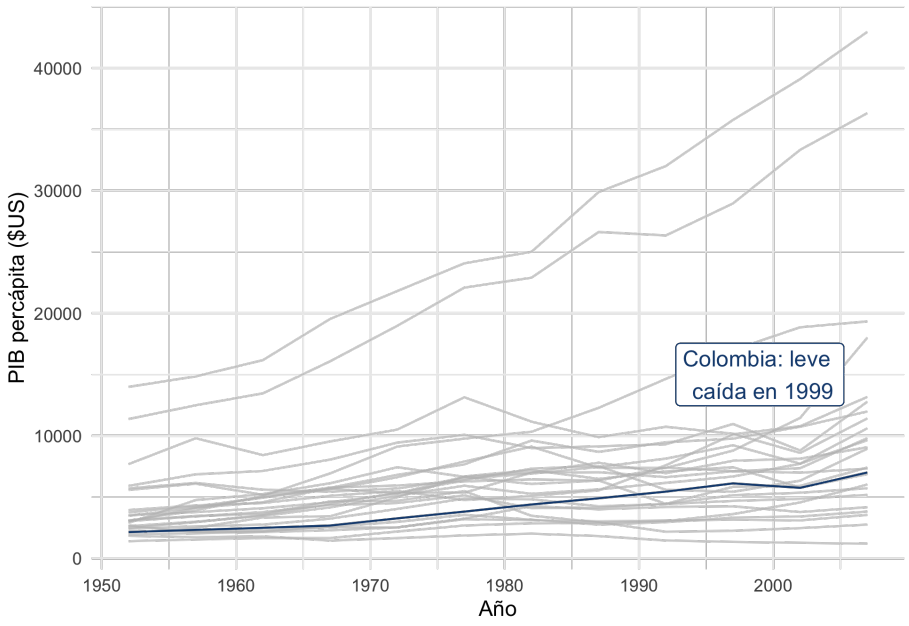

Fuente: Cálculos propios empleando datos del paquete gapminder.

Para generar la Figura 6.6 empleamos por primera vez la función **geom_label()** que incluye una capa con texto (capa de **Texto**). Esta función requiere tres argumentos: los primeros dos corresponden a las coordenadas en las que se pondrá el inicio de la leyenda (argumentos **x** y **y**), el tercer argumento es el texto de la etiqueta (**label**). El código que generó la Figura 6.6 es el siguiente:

```
gapminder %>%
   filter(continent == c("Americas")) %>%
  ggplot( aes(x = year, y = gdpPercap, group = country )) +
    geom_line(col= BLUE1) +
   labs(x = "Año", y = "PIB percápita ($US)",
         color = "País") +
  geom_label( x=1999, y=15000,
              label="Colombia: leve \n caída en 1999",
              size=4, color = BLUE1) +
    theme_minimal() +
    theme(legend.position="none") +
  gghighlight(country == 'Colombia', use_direct_label = F)
```

6.4 No uses gráficos de torta

Los gráficos de torta o pastel (*pie charts*) suelen ser utilizados para mostrar proporciones, donde la suma de todos los grupos da el 100 %. Estos gráficos no son recomendados porque el ojo humano no es bueno midiendo ángulos. El uso de los gráficos de pastel termina distorsionando la información al no lograr comunicar de forma efectiva el mensaje. Resulta complicado ordenar o determinar qué grupo es el más grande, como se ve en la Figura 6.7.

Figura 6.7. Gráfico de torta

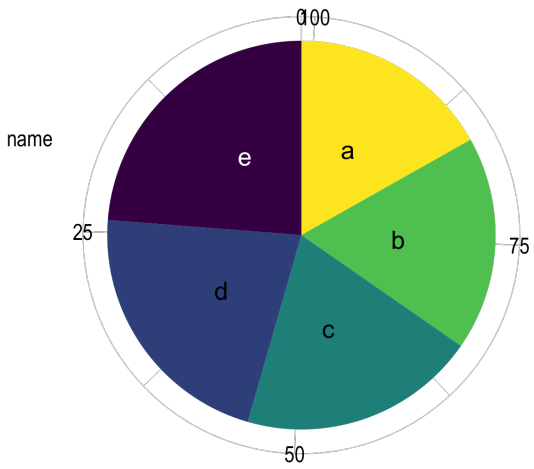

Fuente: Cálculos propios empleando datos simulados.

Una alternativa para presentar los datos con mayor claridad es el gráfico de barras (ver Sección 3.2) con el que se presenta en la Figura 6.8. Esta visualización resulta mucho más sencilla de leer.

Figura 6.8. Gráfico de barras como alternativa al gráfico de pastel (se emplean los mismos datos del grafico de pastel)

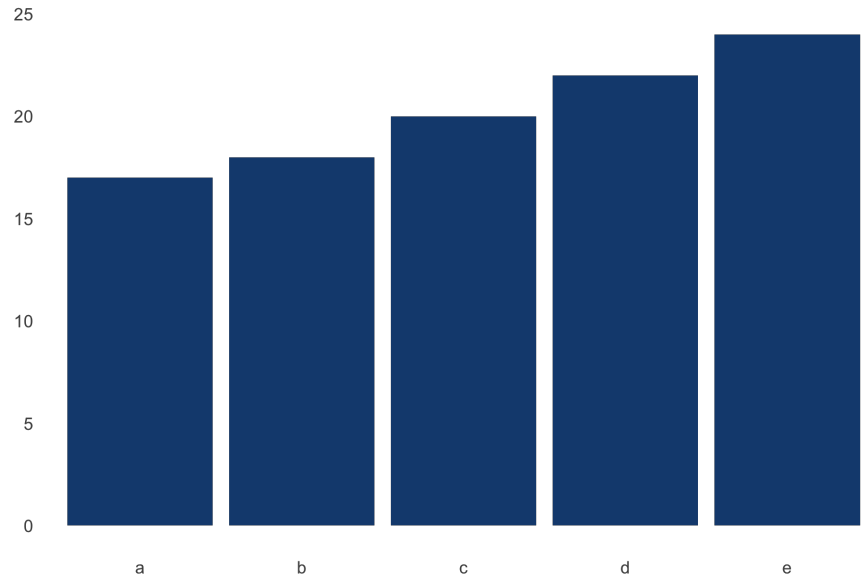

Fuente: Cálculos propios empleando datos simulados.

En resumen, no uses los gráficos de pastel y menos aquellos en 3D. Los gráficos de pastel en 3D resultan aún peor para la lectura de la información.

6.5 Comentarios finales

En este capítulo hemos visto cómo agregando unos pocos elementos podemos mejorar una visualización. Organizar los datos, emplear los colores para comunicar una idea y agregar texto pueden ser herramientas muy potentes para mejorar tus visualizaciones. Y todo esto lo podemos hacer rápidamente con *ggplot2*.

Ya contamos con una caja de herramientas llena de potentes funciones que te permitirán generar visualizaciones. Pero tal vez la herramienta más importante al momento de construir una visualización, es la paciencia. Debemos intentar diferentes configuraciones de las capas hasta llegar a una visualización que transmita el mensaje que deseamos. Ensayar y errar hacen parte del proceso de construcción de una visualización.

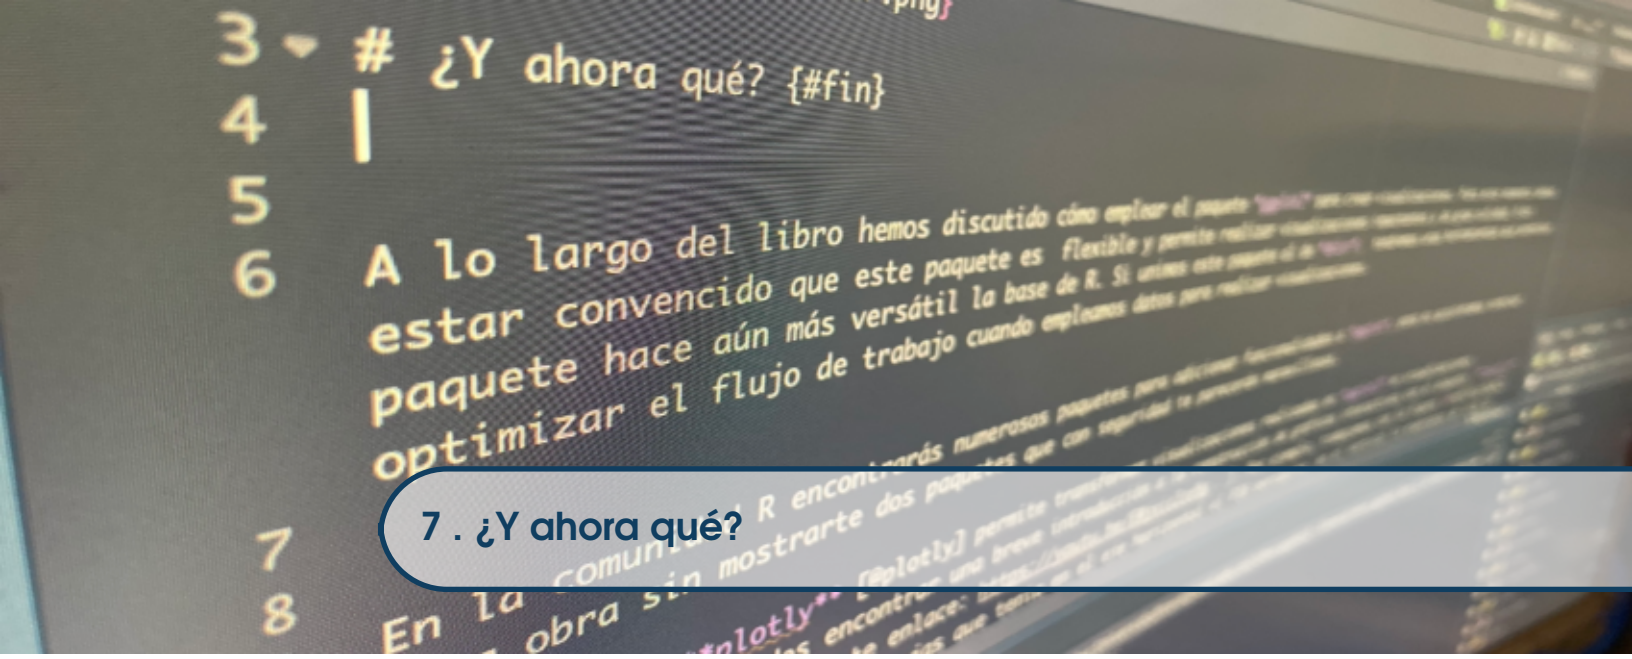

A lo largo del libro hemos discutido cómo emplear el paquete *ggplot2* para crear visualizaciones. Para este momento debes estar convencido que este paquete es flexible y permite realizar visualizaciones impactantes y de gran calidad. Este paquete hace aún más versátil la base de R. Si unimos este paquete al de *dplyr*, tendremos unas herramientas que permiten optimizar el flujo de trabajo cuando empleamos datos para realizar visualizaciones.

En la comunidad R encontrarás numerosos paquetes para adicionar funcionalidades a *ggplot*, pero no quisiéramos terminar esta obra sin mostrarte dos paquetes que con seguridad te parecerán maravillosos.

El paquete **plotly** (Sievert, 2020) permite transformar visualizaciones realizadas en *ggplot2* en visualizaciones interactivas[1]. Por ejemplo, trabajemos con la Figura 5.5. Esta era un gráfico de burbujas que tenía en el eje horizontal el PIB percápita, en el vertical la esperanza de vida al nacer, el tamaño de cada punto es la población y el color corresponde al continente. Recreemos ese gráfico y guardémoslo en un objeto.

```
# cargamos los paquetes
library(ggplot2)
library(dplyr)
library(gapminder)

# se guarda el gráfico en un objeto
g1 <- gapminder %>%
  filter(year == 2007) %>%
```

[1]Puedes encontrar una breve introducción a la construcción de gráficos interactivos con el paquete **plotly** (Sievert, 2020) en el siguiente enlace: https://youtu.be/EWjxic2ce9g .

```
  ggplot(aes(x = gdpPercap, y = lifeExp,
             size = pop, col = continent )) +
  geom_point() +
  labs(  x = "PIB percápita ($US)",
         y = "Esp. de vida",
         size = "Población",
         col = "Continente") +
  theme_minimal() +
   theme(legend.position = "bottom")
```

Ahora podemos animar este gráfico empleando solo una línea de código. La función **ggplotly()** del paquete *plotly* (Sievert, 2020) solo requiere como argumento un objeto de clase **ggplot**. Es decir, la Figura 7.1 la podemos crear con la siguiente línea de código.

```
# instala el paquete si no o tienes
# install.packages("plotly")
# cargamos el paquete
library(plotly)
# convertimos a interactivo el gráfico
ggplotly(g1)
```

Figura 7.1. Gráfico interactivo de la relación del PIB percápita, la esperanza de vida y población alrededor del mundo (2007)

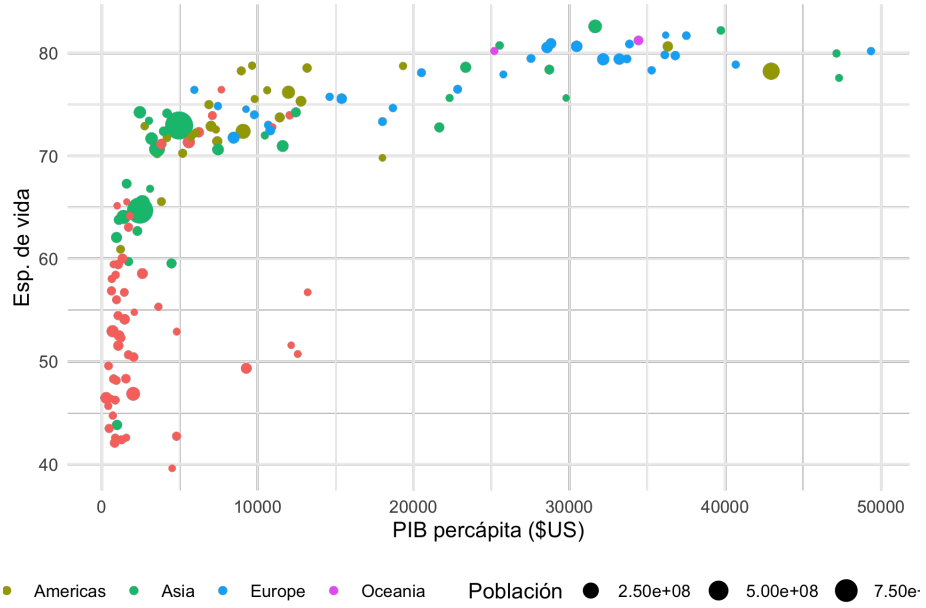

Fuente: Cálculos propios empleando datos simulados.

Este tipo de visualizaciones (ver Figura 7.1) permiten al usuario interactuar con los datos. Juega un rato con este gráfico. Se pueden apagar los continentes y hacer *zoom*. Pasa el cursor por encima de un punto para ver la información. La interacción solo funciona en la versión web del libro (https://www.icesi.edu.co/editorial/empezando-usar-web/).

Otro paquete que puede llevar tus visualizaciones a otro nivel es *gganimate* (Pedersen y Robinson, 2020). Este paquete permite generar gráficos animados como el de la Figura 7.2. Este gráfico no es interactiva como la Figura 7.1, pero sí permite ver la evolución en el tiempo de la misma relación entre la esperanza de vida como el PIB percápita. Aquí podemos ver cómo, por continente, han mejorado tanto la esperanza de vida como el PIB percápita. La animación solo funciona en la versión web del libro (https://www.icesi.edu.co/editorial/empezando-usar-web/).

Figura 7.2. Visualización animada de la evolución del PIB percápita y la esperanza de vida alrededor del mundo (1952-2007).

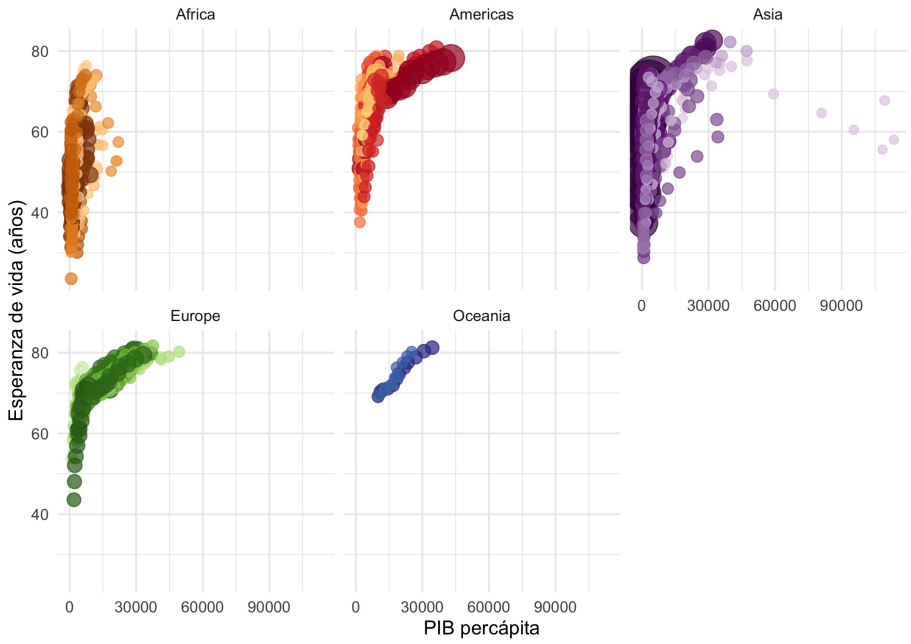

Fuente: Cálculos propios empleando datos simulados.

El código que produce la Figura 7.2 se presenta a continuación. No es tan complicado, pero debes seguirlo con cuidado y nota que estamos empleando nuevas funciones de *ggplot2* como **facet_wrap()** y **scale_colour_manual()**. No obstante estas funciones son nuevas para ti, con lo aprendido hasta ahora ya puedes saber cuáles son las capas que modifican estas funciones. Y recuerda que siempre está disponible la ayuda y la documentación para aprender más sobre las nuevas funciones.

```
g.anidado <- ggplot(gapminder, aes(x = gdpPercap, y= lifeExp,
                                   size = pop, colour = country)) +
  geom_point(alpha = 0.7, show.legend = FALSE) +
  scale_colour_manual(values = country_colors) +
  scale_size(range = c(2, 12)) +
  facet_wrap(~continent) +
    theme_minimal() +
  labs(title = 'Año: {frame_time}',
       x = 'PIB percápita',
       y = 'Esperanza de vida (años)') +
  transition_time(year) +
  ease_aes('linear')

g.anidado
```

Estas visualizaciones interactivas y animadas son ejemplo de lo versátil que es R para generar visualizaciones de tus datos. Esperamos que esta obra te motive a continuar tu camino de aprendizaje y unirte a la gran comunidad de R. En este universo de R, ¡la imaginación es el límite!

Bibliografía

Abela, A. (2008). *ADVANCED PRESENTATIONS BY DESIGN*. Pfeiffer.

Alonso, J. C. (2021). Una introducción a los Loops en R (y algunas alternativas). Icesi Economics Lecture Notes 019408, Universidad Icesi.

Alonso, J. C. (2022). Empezando a transformar bases de datos con r y dplyr.

Alonso, J. C. y González, A. (2012). Ggplot: gráficos de alta calidad. *Apuntes de Economía*, (33):29.

Alonso, J. C. y Ocampo, M. P. (2022). Empezando a usar: Una guía paso a paso.

Bryan, J. (2017). *gapminder: Data from Gapminder*. R package version 0.3.0.

Henry, L. y Wickham, H. (2020). *purrr: Functional Programming Tools*. R package version 0.3.4.

Moreno, D. (2015a). *colmaps: Colombian maps*. R package version 0.0.0.9515.

Moreno, D. (2015b). *homicidios: Colombian homicides data*. R package version 0.0.0.9000.

Müller, K. y Wickham, H. (2021). *tibble: Simple Data Frames*. R package version 3.1.6.

Pedersen, T. L. y Robinson, D. (2020). *gganimate: A Grammar of Animated Graphics*. R package version 1.0.7.

R Core Team (2018). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria.

Sievert, C. (2020). *Interactive Web-Based Data iczation with R, plotly, and shiny*. Chapman and Hall/CRC.

Wickham, H. (2016). *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York.

Wickham, H. (2019). *stringr: Simple, Consistent Wrappers for Common String Operations*. R package version 1.4.0.

Wickham, H. (2020). *forcats: Tools for Working with Categorical Variables (Factors)*. R package version 0.5.0.

Wickham, H. (2021). *tidyr: Tidy Messy Data*. R package version 1.1.3.

Wickham, H., Averick, M., Bryan, J., Chang, W., McGowan, L. D., François, R., Grolemund, G., Hayes, A., Henry, L., Hester, J., Kuhn, M., Pedersen, T. L., Miller, E., Bache, S. M., Müller, K., Ooms, J., Robinson, D., Seidel, D. P., Spinu, V., Takahashi, K., Vaughan, D., Wilke, C., Woo, K., y Yutani, H. (2019). Welcome to the tidyverse. *Journal of Open Source Software*, 4(43):1686.

Wickham, H., François, R., Henry, L., y Müller, K. (2021). *dplyr: A Grammar of Data Manipulation*. R package version 1.0.7.

Wickham, H. y Grolemund, G. (2016). *R for data science: import, tidy, transform, visualize, and model data*. .°'Reilly Media, Inc.".

Wickham, H., Hester, J., y Francois, R. (2018). *readr: Read Rectangular Text Data*. R package version 1.3.1.

Wilkins, D. (2019). *treemapify: Draw Treemaps in 'ggplot2'*. R package version 2.5.3.

Wilkinson, L. (2012). The grammar of graphics. In *Handbook of computational statistics*, pages 375–414. Springer.

Yutani, H. (2020). *gghighlight: Highlight Lines and Points in 'ggplot2'*. R package version 0.3.1.

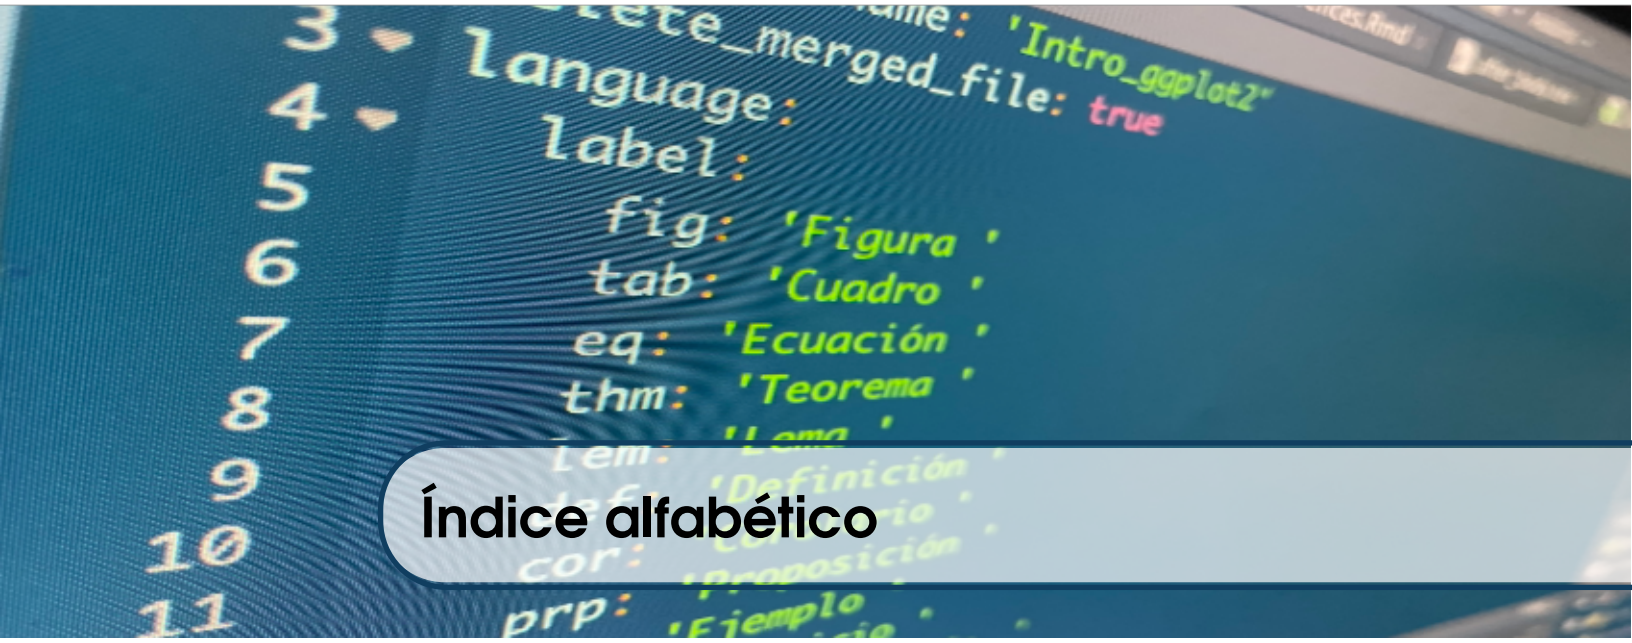

Índice alfabético

Editorial Universidad Icesi

UNIVERSIDAD ICESI

Si estás leyendo *Empezando a visualizar datos con R y ggplot2*, es porque haces parte de la comunidad que emplea R para analizar datos. Este libro tiene como objetivo presentar una primera aproximación a visualizar datos empleando el paquete *ggplot2*. Este paquete permite realizar visualizaciones rápidamente y de manera más intuitiva que la base de R. Si eres nuevo en el universo de R o en el uso del paquete ggplot2, este libro puede ser un buen punto de arranque. Si ya eres usuario de *ggplot2*, seguramente este libro no te aportará nuevos conocimientos, pero puede ser una herramienta de consulta de algunos conceptos básicos.

Herramientas del BIG DATA y analytics