

Proyecto Métodos Estadísticos

Alejandro Jesús González Santana

29/11/2021

DNI: 45394160A

Vídeo presentación:

https://alumnosulpgc-my.sharepoint.com/:v/g/personal/alejandro_gonzalez147_alu_ulpgc_es/EXj8HZCYuwpHookm6buyWiUB6lqLp2Uu6WTH5iudvAJegA?e=wBqwWb

Presentación:

https://alumnosulpgc-my.sharepoint.com/:p/g/personalalejandro_gonzalez147_alu_ulpgc_esEWzV7sZL8fVHh2niPEEMuRkBB0n6dB8bAfoZLTDcCVHG7g?e=Qaw7m9

Vídeo Web:

https://alumnosulpgc-my.sharepoint.com/:v/g/personal/alejandro_gonzalez147_alu_ulpgc_es/Edr5N13y1gFEuRNXRqJhhH0a9ElcE9gxhhFA?e=knX6fd

Bases del proyecto:

El proyecto consiste en una recorrido a través de los acontecimientos históricos que han marcado el declive del medio ambiente. La elección del tema fue fácil para mí, ya que una de mis pasiones es la geografía y las culturas. Había conocido casos como Haití, donde la gente vive entre basura y en condiciones precarias debido a los desastres naturales, o Kiribati, una pequeña nación del Océano Pacífico, que es una de las regiones más expuestas al crecimiento del nivel del mar. Por ello, este proyecto se presenta como un medio para adentrarme en la investigación sobre los vínculos entre países y cambio climático. Los datos son una herramienta más potentes para comprobar como se encuentra el mundo en un instante determinado, es por ello que las gráficas pueden llegar a ser un reflejo de la historia, y junto a ello podemos comprobar los errores que hemos cometido como sociedad.

Durante el proyecto, se resolverán los siguientes temas:

- o
- Recorrido histórico a través de las emisiones de CO2.
- Descubrir el peligro del nivel del mar.
- Conocer si los países con mayores ingresos son los más contaminantes.
- Conocer la relación entre emisiones y cambio climático.
- Conocer si la población de un país es un factor clave en la contaminación que este produce.
- Transporte y consumo individual reflejados en las emisiones de CO2.
- El coronavirus como punto de retorno.

Definiciones:

- Cambio climático: se refiere a una serie de factores que suponen una fluctuación en los parámetros estándares del clima de nuestro planeta. Este se puede ver afectado a través del calentamiento global, movimientos del eje terrestre o la actividad volcánica.
- Calentamiento global: se refiere a la aparición de fenómenos de temperaturas extremas, con un incremento de la temperatura que genera la pérdida de cosechas, la subida del nivel del mar y más consecuencias que forman parte del llamado cambio climático.
- Emisiones de Efecto invernadero: son aquellos gases que se concentran en la atmósfera terrestre y absorben la radiación infrarroja que proviene del Sol. Algunos de estos gases son el metano(CH4), el dióxido de carbono(CO2) o LOS clorofluorocarburos (CFC). Son la principal causa de contaminación y por ende de fenómenos como el calentamiento global o el cambio climático.

Data frame principal:

El proyecto se basará en análisis de ciertos factores respecto a la emisiones de CO2, por lo tanto nuestro data frame inicial contendrá los datos sobre las emisiones. En este caso, tenemos datos de las emisiones de CO2 por país desde 1750 a 2020, en ciertas filas los datos pueden estar completados con ceros, esta tendencia podría deberse a una falta de datos en años tempranos pero vamos a suponer que en esos años las emisiones eran nulas respecto a la actualidad.

- Hannah Ritchie and Max Roser (2020) - “CO2 and Greenhouse Gas Emissions”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/co2-and-other-greenhouse-gas-emissions> [Online Resource]

annual-co-emissions-by-region.csv: se trata de un data frame, que contiene la información acerca las emisiones de carbono por país anuales. La primera columna indica el país, la segunda es una abreviatura o código del país, y la última nos da los datos sobre las emisiones de dióxido de carbono en toneladas.

```
emisiones_anuales_co2 <- read.csv("annual-co-emissions-by-region.csv", header = TRUE, sep
↵ = ",")
```

```
head(emisiones_anuales_co2)
```

```
##      Entity Code Year Annual.CO2.emissions..zero.filled.
## 1 Afghanistan AFG 1750                                0
## 2 Afghanistan AFG 1751                                0
## 3 Afghanistan AFG 1752                                0
## 4 Afghanistan AFG 1753                                0
## 5 Afghanistan AFG 1754                                0
## 6 Afghanistan AFG 1755                                0
```

```
str(emisiones_anuales_co2)
```

```
## 'data.frame':    64260 obs. of  4 variables:
##  $ Entity      : chr  "Afghanistan" "Afghanistan" "Afghanistan" "Afghanistan"
##  $ Code        : chr  "AFG" "AFG" "AFG" "AFG" ...
##  $ Year        : int  1750 1751 1752 1753 1754 1755 1756 1757 1758 1759 ...
##  $ Annual.CO2.emissions..zero.filled.: num  0 0 0 0 0 0 0 0 0 0 ...
```

Como podemos observar se trata de un dataframe que contiene información diversa sobre los países y su generación de CO2 con el consumo de combustibles fósiles y la producción de energía. La primera columna nos da el nombre del país, la segunda un código que indica las iniciales del país, la tercera hace referencia al año al que se corresponde la emisión de CO2 y la cuarta a la susodicha generación de CO2.

Podemos denominar estos datos como la base de este proyecto, ya que esta será la gráfica principal respecto a la cual se realizan todas las comparaciones. En primer lugar, vamos a desplazarnos a Reino Unido.

La Revolución Industrial, el comienzo de la contaminación masiva:

```
library(tibble)
library(dplyr)
```

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

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

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

```
emisiones_anuales_co2<-as_tibble(read.csv("annual-co-emissions-by-region.csv", header =
↪ TRUE, sep = ","))
datos_co_uk <- filter(emisiones_anuales_co2, Entity == "United Kingdom")
```

En el code chunk anterior he usado la librería tibble para organizar mejor los datos de nuestro data frame anterior. Con la librería dplyr vamos a filtrar nuestros datos para seleccionar únicamente las filas que pertenezcan a Reino Unido. Esta opción nos la permite la función filter.


A continuación vamos a visualizar los datos que a acabamos de conseguir con el data frame “datos_co_uk”. Para ello usaremos ggplot2:

```
library(ggplot2)
max(datos_co_uk$Annual.CO2.emissions..zero.filled.)
```

```
## [1] 660388284
```

```
emisiones_co_uk_gráfica <- ggplot((data = datos_co_uk)) +
  geom_point(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled.),
  ↪ col = "Blue") + xlab("Años") + ylab("Emisiones CO2") + ggtitle("Emisiones
  ↪ de CO2 Reino Unido")
emisiones_co_uk_gráfica
```

Emisiones de CO2 Reino Unido




Como se puede observar en la gráfica anterior, Reino Unido sigue la tendencia histórica que podrían seguir muchos países actuales. El caso de Reino Unido sin embargo, es muy peculiar. Observemos en un rango más pequeño, por ejemplo hasta 1800, para que se ajuste al inicio de nuestra gráfica, para ello, volveremos a ajustar nuestro data frame a un rango inferior:

```
emisiones_co_uk_1750a1800 <- ggplot((data = datos_co_uk)) +  
  geom_line(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled.), col  
  ↵ = "Blue") + xlab("Años") + ylab("Emisiones CO2") + ggtitle("Emisiones de  
  ↵ CO2 Reino Unido de 1750 a 1800") + xlim(1750, 1800) + ylim(0, 30000000)  
emisiones_co_uk_1750a1800
```

```
## Warning: Removed 219 row(s) containing missing values (geom_path).
```

Emisiones de CO2 Reino Unido de 1750 a 1800

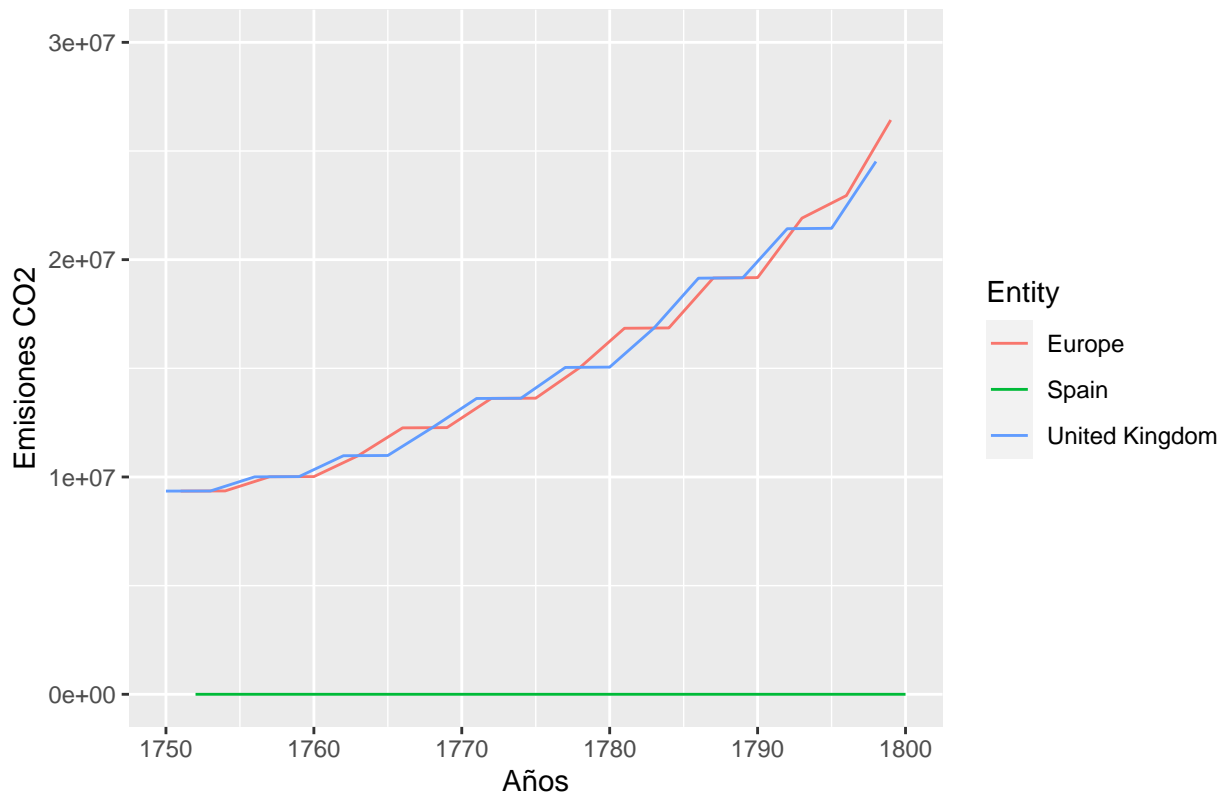


Si observamos la gráfica resultante Reino Unido en 1750 emitió alrededor de los 10 millones de toneladas. Pero vamos a ver una diferencia más clara aún. Comparemos en una misma gráfica a Reino Unido, Europa y España. Para ello vamos a realizar un filtro sobre el data frame con todos los países, pero esta vez eligiendo también a España y a Europa.

```
Europa_uk_España <- c("United Kingdom", "Europe", "Spain")
datos_europa_uk <- filter(emisiones_anuales_co2, Entity == Europa_uk_España)
emisiones_co_uk_1750a1800_europa <- ggplot((data = datos_europa_uk)) +
  geom_line(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled.)) +
  ↪ xlab("Años") + ylab("Emisiones CO2") + ggtitle("Emisiones de CO2 Europa,
  ↪ España y Reino Unido entre 1750 a 1800") + xlim(1750, 1800) + ylim(0,
  ↪ 30000000)
emisiones_co_uk_1750a1800_europa + aes(col = Entity)
```

```
## Warning: Removed 219 row(s) containing missing values (geom_path).
```

Emisiones de CO2 Europa, España y Reino Unido entre 1750 a 1800



En esta última gráfica podemos observar que claramente Reino Unido contribuye en gran parte a las emisiones de Europa. Por otro lado, España apenas contribuye a las emisiones de CO2 a finales del siglo XVIII.

La Revolución Industrial surgió en Reino Unido en 1750, justo en el año en el que comienzan nuestros datos. Esta supuso un éxodo de la población desde los campos hasta las ciudades, en busca de mejorar su calidad de vida, así como, un gran avance en la mecanización de la producción en cadena, sin embargo el ahorro de tiempo y procesos, se tradujo en el uso de máquinas que consumían combustible, principalmente carbón, que emitía CO2 a la atmósfera. Durante esta etapa fueron inventadas las máquinas de vapor, el barco de vapor y el ferrocarril, entre otras, lo que disparó la emisión de CO2 también en los transportes.

La Revolución Industrial se extendería por Europa a lo largo de la segunda mitad del siglo XIX y principios del siglo XX. La gráfica nos muestra la relevancia de esa revolución industrial, sobre todo en Reino Unido que ocupaba la mayor parte de la industria europea. Mientras tanto, podemos observar que Alemania que era un país con cierta industria desarrollada, apenas emitía en comparación con el gigante británico.


Por ejemplo, España no hubiera podido ser elegido para el gráfico, debido al escaso desarrollo industrial y a que la Revolución Industrial llegó más tarde a nuestro país.

El comienzo de la industria española:

Vamos a estudiar ahora el desarrollo en nuestro país, para ello vamos a ver la gráfica de emisiones de CO2:

```
datos_españa <- filter(emisiones_anuales_co2, emisiones_anuales_co2$Entity == "Spain")
gráfico_españa <- ggplot(data = datos_españa) + geom_line(mapping = aes(x = Year, y =
↪ Annual.CO2.emissions..zero.filled.), col = "red", lwd = 2) + xlab("Años") +
↪ ylab("Emisión de CO2") + ggtitle("Emisión de CO2 en España")
gráfico_españa
```

Emisión de CO2 en España



La gráfica anterior nos muestra que España no tuvo un crecimiento tan precoz como Reino Unido en cuanto a las emisiones, sino que estas se dispararon una vez avanzados en el siglo XX.

<https://ourworldindata.org/grapher/shares-of-gdp-by-economic-sector?country=~SWE>

A continuación, voy a emplear un nuevo data frame que contiene el peso de los tres sectores económicos sobre el Producto Interior Bruto de un país para comprobar nuestra hipótesis.

```
datos_economicos <- read.csv("shares-of-gdp-by-economic-sector.csv", header = TRUE, sep  
→ = ",")
```

```
países_Economía <- c("Spain", "United Kingdom", "Netherlands")  
datos_economicos_ordenados <- as_tibble(datos_economicos)
```

```
datos_economicos_comparar <- filter(datos_economicos_ordenados,  
→ datos_economicos_ordenados$Entity == países_Economía)
```

```
## Warning in datos_economicos_ordenados$Entity == países_Economía: longitud de  
## objeto mayor no es múltiplo de la longitud de uno menor
```

```
gráfica_industria <- ggplot(data = datos_economicos_comparar) + geom_line(mapping =  
→ aes(x = Year, y =  
→ Share.of.industry.in.GDP.at.current.prices..Herrendorf.et.al..data.)) + xlab("Años")  
→ + ylab("Porcentaje de la industria en PIB") + ggtitle("Comparación industria en  
→ Holanda, Esapaña y Reino Unido")  
gráfica_industria <- gráfica_industria + aes(col = Entity)  
gráfica_industria
```

Comparación industria en Holanda, España y Reino Unido



```
gráfica_industria + geom_vline(xintercept = 1930)
```


Comparación industria en Holanda, España y Reino Unido



https://es.wikipedia.org/wiki/Milagro_econ%C3%B3mico_espa%C3%B1ol

Para crear esta gráfica hemos seguido un proceso muy similar a las anteriores, usamos la librería dplyr para filtrar un data frame base, y a continuación, creamos una gráfica con ggplot2. He decidido seleccionar a Reino Unido y a Holanda para realizar una comparación con España porque ambos son países típicamente industriales.

La línea negra divide nuestra gráfica en dos, con un punto crítico en 1930, que marcará un antes y un después en nuestro país. Comencemos por explicar en primer lugar el comienzo del siglo XIX.


En este caso, la gráfica esbozada es un fiel reflejo de las bajas emisiones de CO₂ por parte de nuestro país a lo largo del siglo XIX y principios del siglo XX, podríamos afirmar que las emisiones de CO₂ y la industria de un país son proporcionales. En cuanto a los datos España presenta sus primeras estadísticas con tardanza respecto a Holanda y Reino Unido, un indicativo de que España no era una de las potencias industriales de ese momento. La Revolución Industrial llegó a nuestro país sobre 1830, sin embargo, esta tardaría más tiempo en asentarse. España tuvo un desarrollo industrial desacelerado en comparación con otros países europeos, por un gran número de inconvenientes que sufría. En aquella época no existían los medios de transporte que facilitan el comercio entre fronteras, sino que el medio más avanzado era el ferrocarril, que no estaba extendido por la Península. España además, poseía escasos recursos energéticos, tan solo disponía de hulla asturiana de muy baja calidad, a lo se sumaba la complicada orografía que impedía la llegada de carbón a industrias siderúrgicas como la malagueña. El punto donde más fructífero fue el comercio fue en el País Vasco, donde comerciaban con Inglaterra acero por carbón.

Todos estos factores sumados al golpe que había dejado la pérdida de las colonias a principios del siglo, así como al escaso capital e infraestructura financiera hicieron que se concedieran derechos a empresas extranjeras sobre las minas españolas. Con ello la industria comenzó a tener un incremento en importancia, sin embargo, los beneficios iban a parar a los países extranjeros que poseían las minas.

La guerra y el Milagro económico español:


A continuación vamos a avanzar un poco en el tiempo para explicar nuestra gráfica desde 1930. Si el comienzo del siglo XIX había sido bastante inestable con las independencias de las colonias americanas, el comienzo del XX no iba a ser menos. En 1898 se consumió la crisis del 98, tras la pérdida de Cuba, Filipinas, Puerto Rico y las Islas Marianas, y la guerra con Estados Unidos, lo que produjo numerosos cambios de Gobierno. En otras partes de Europa comenzaban a fluir las corrientes ideológicas que llegarían a España más tarde, con la división en izquierda y derecha. Ya existió una primera dictadura con Primo de Rivera, sin embargo, aquella vez la dictadura fue aceptada por la población y no existió una gran oposición. Primo de Rivera no mejoró la situación del país, lo que causó su dimisión en 1930. En este escenario se turnaban los Gobiernos de izquierdas y derechas, en medio de este caos se desencadenaron una serie de conflictos entre ambas ideologías, que acabarían con un golpe de Estado por parte de Franco en 1936. A diferencia de la primera dictadura, en esta ocasión el Golpe de Estado fue motivo de discrepancias entre la población. La secuencia de los hechos empujó al país a una Guerra Civil que se inició en 1936 y finalizó en 1939 con la victoria del bando nacional.

```
gráfica_industria + geom_vline(xintercept = 1930) + geom_vline(xintercept = 1940)
```



```
gráficoo_españa + geom_vline(xintercept = 1936) + geom_vline(xintercept = 1940)
```

Emisión de CO2 en España



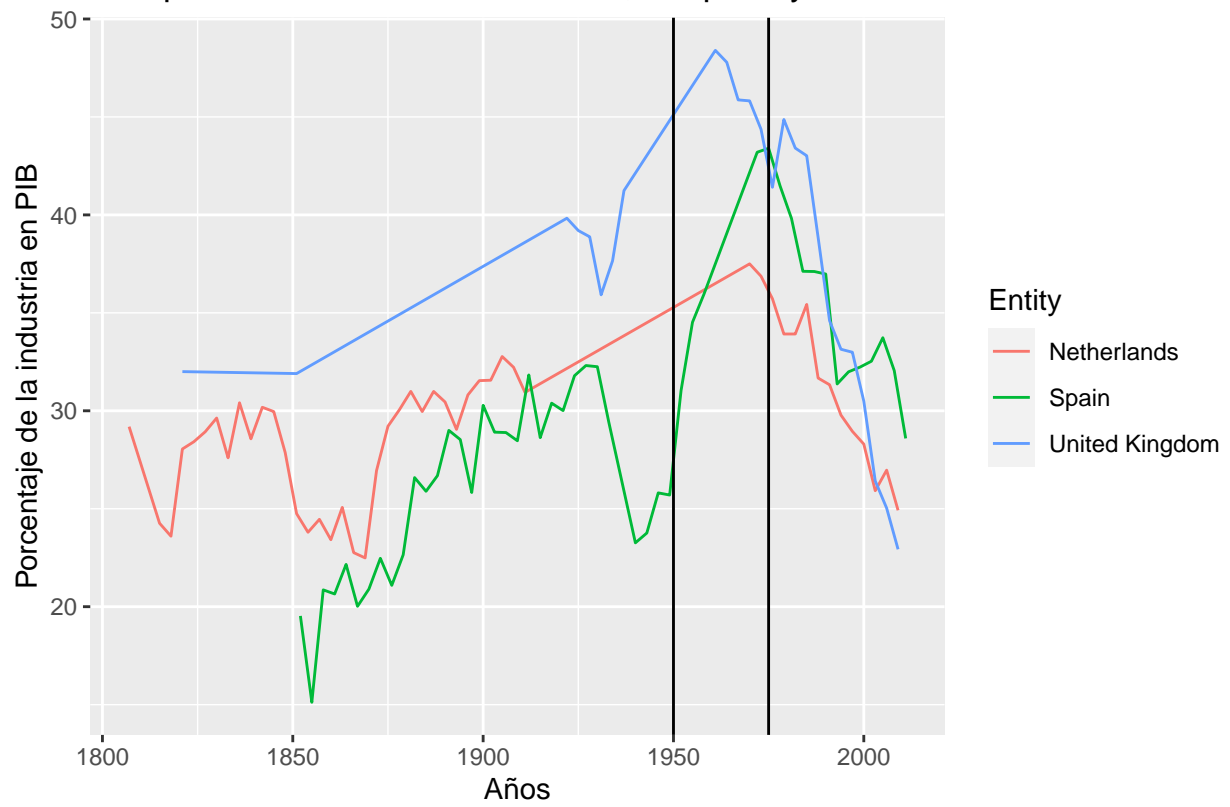
En la gráfica se ve reflejado este período de controversia e inestabilidad con una decaída de la industria entre 1930 y 1940, la Guerra Cívil también afecto inmediatamente a la emisiones de CO2 con un decrecimiento entre 1936 y 1939.

Sin embargo, tras la guerra y durante la dictadura franquista, tuvo lugar el Milagro Español. La dictadura fue rechazada por los países que poseían gobiernos democráticos, como Estados Unidos, lo que supuso un duro revés para la recuperación económica del país. España sufría una crisis importante, al quedar bloqueado cualquier comercio exterior tras las caídas de la dictadura en Portugal y Alemania. Sin embargo, España y Estados Unidos tenían un lazo de unión, el odio hacia el comunismo de la Unión Soviética. España fue aliada de Estados Unidos en la Guerra Fría, cediendo bases al país americano. Todo ello supuso una mejoría económica, que vino acompañada del reconocimiento estadounidense y el ingreso a la ONU.

En este contexto el Gobierno militar fue sustituido por un Gobierno compuesto por tecnócratas. El FMI(Fondo Monetario Internacional) aconsejó a los tecnócratas, que crearon los Planes de Desarrollo. Con estos planes se experimentó un crecimiento exponencial, que supuso una gran tasa de crecimiento en la economía española, tan solo superada en ese período por la japonesa. Sin embargo, al crecimiento industrial se le sumaban los daños ecológicos y una desaceleración sobre 1970 a causa de la crisis del petróleo.


```
gráfica_industria + geom_vline(xintercept = 1950) + geom_vline(xintercept = 1975)
```

Comparación industria en Holanda, España y Reino Unido



```
gráfico_españa + geom_vline(xintercept = 1950) + geom_vline(xintercept = 1980)
```

Emisión de CO2 en España



En la gráfica esta etapa se traduce en un crecimiento en el peso de la industria sobre el PIB de nuestro país entre 1950 y 1970 con su posterior declive a causa de la crisis. De igual manera, se aprecia un pequeño declive en las emisiones de CO₂, aunque, hay que tener en cuenta que para entonces, la industria ya no era el foco principal emisor de CO₂, si no que ya existían los automóviles y ferrocarriles a lo largo de todo el país.

La declaración del milenio y otras medidas:


Con la llegada del nuevo milenio, la ONU convocó una reunión en su sede en Nueva York el 8 de septiembre del 2000. En ella se insertarían una serie de principios y valores con el consenso de sus miembros para mejorar el mundo. Uno de los objetivos marcados fue el garantizar la sostenibilidad del medio ambiente.

El problema no estaba solo implícito en el acuerdo, la sociedad poco a poco iba tomando conciencia del problema que estaban generando nuestras acciones.

A raíz de ello, se han abordado acuerdos como el Tratado de París(2015), cuyo interés es frenar el calentamiento global así como reducir las emisiones de gases de efecto invernadero. La forma en la que funciona es secuencial, cada cinco años se vuelven a replantear nuevas medidas. Su objetivo para 2030 es el impulso de soluciones de emisión cero.

```
gráfico_españa + geom_vline(xintercept = 2005)
```

Emisión de CO2 en España



En la gráfica podemos observar una tendencia a la baja en las emisiones en España, que podría estar relacionada con el comienzo de la concienciación, aunque hay que recordar que España sufrió en 2008 una importante crisis económica que pudo ser clave para que la tendencia quede más remarcada aún.

Pese a la crisis, da la sensación de que tras la recuperación las emisiones se han estabilizado en unos niveles menores a los que precedían al 2008.

Una de las medidas más comentadas ha sido Madrid Central, acuerdo que es digno de mención pese a no ser de índole internacional. Madrid Central fue un proyecto impulsado en 2018 en Madrid, pero que fue aplicado en 2020 tras varias apelaciones a la Justicia dado la controversia que causó. Madrid central restringe un perímetro del centro de la ciudad de Madrid para crear una zona de emisiones cero, para ello se prohíbe la entrada de coches sin etiqueta medioambiental (motor diésel matriculados antes del 2006 y motor gasolina) que no estén domiciliados en Madrid.

De este apartado de la historia de España podemos sacar las siguientes conclusiones:


- En un principio, las emisiones de CO2 eran proporcionales a la industria, ambas crecían a medida que esta última se desarrollaba.
- Las grandes crisis o las guerras mermaban la economía y con ello la industria, por lo que eran períodos en los que las emisiones disminuían.
- La estabilidad de un país puede traducirse en una mejoría económica, que incluye un aumento en la industria y en las emisiones.
- Desde comienzos del milenio, el mundo ha comprendido la dimensión del calentamiento global y sus consecuencias, por lo que las grandes organizaciones y Estados han tomado medidas para disminuir los gases de efecto invernadero.

Guerras, ¿períodos sin contaminación?:

De la gráfica anterior de España, pudimos concluir que los períodos de guerra son convulsos en numerosos aspectos, no solo son capaces de separar poblaciones, y dejar incontables pérdidas humanas, culturales o materiales, si no que también dan, según los datos, un descanso a nuestro planeta de la industria y su polución. Pero, ¿es esto realmente así?:

Primero vamos a volver a usar nuestra gráfica de las emisiones, pero en esta ocasión nos situaremos en un punto crítico, no solo para Europa, sino que también para el mundo. Vamos a fijarnos en la gráfica de las emisiones de dióxido de carbono, en esta ocasión con otros países situémonos en 1936:

```
países_guerra <- c("United Kingdom", "France", "Russia", "Germany", "Italy", "Japan",
↳ "United States")
datos_segunda_guerra <- filter(emisiones_anuales_co2, emisiones_anuales_co2$Entity ==
↳ países_guerra)
emisiones_co_guerra <- ggplot((data = datos_segunda_guerra)) +
geom_line(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled.))+
↳ xlab("Años") + ylab("Emisiones CO2") + ggtitle("Emisiones CO2 participantes Segunda
↳ Guerra Mundial")
emisiones_co_guerra + aes(col = Entity) + geom_vline(xintercept = 1939)
```



En este gráfico tenemos reunidas las emisiones durante la Segunda Guerra Mundial (1939 a 1945) y sus poblaciones son los países involucrados. La Guerra que comenzó en el año en el que acabó la Guerra Civil Española, fue resultado de las grandes diferencias ideológicas y la tensión acumulada. A principios del siglo XX, en Europa aún existían férreas dictaduras como en Alemania con Hitler, en Italia con Mussolini, Portugal con Salazar y nuestro país como ya mencionamos anteriormente, simultáneamente proliferaban democracias

mundiales como la francesa, la estadounidense o la británica. Los dictadores querían tener grandes imperios y por ello buscaban la expansión del territorio nacional. Ese deseo de colonización fue el que impulsó a la Alemania nazi a invadir Polonia con un ataque simulado como pretexto, un deseo que provocaría el estallido de la Segunda Guerra Mundial. Los bandos estaban bien marcados, por un lado encontrábamos a las potencias del eje, caracterizados por su imperialismo estaban conformadas por Alemania, Italia y Japón. Las potencias del eje se enfrentaban a los Aliados, cuyas principales potencias eran Francia, Reino Unido, Estados Unidos y la Unión Soviética. La guerra tuvo como escenarios principales Europa y el sureste asiático, durante seis arduos años, que culminaron con la victoria del bando de los aliados. Una de las causas de la rendición del bando imperial fue la explosión de una bomba nuclear en Nagasaki e Hiroshima por parte de los Estados Unidos. Tras la victoria en la guerra los vencedores se repartieron los territorios ocupados por los vencidos, lo que causó un frente enrumbamiento entre Estados Unidos y la Unión Soviética en su empeño por imponer el capitalismo y el comunismo, respectivamente. Esta lucha ideológica influyó claramente en la industria española como vimos anteriormente, dado que de ella surgieron la Guerra Fría donde España apoyó a Estados Unidos y consiguió salir del aislamiento.

El gráfico es la muestra de las depresiones en la producción de los países donde se producen las guerras, ya que algunos países europeos y Japón sufrieron una caída en las emisiones de CO₂, lo que podemos entender como un breve descanso para nuestra atmósfera y planeta. Sin embargo, hemos mencionado que uno de los desencadenantes de la guerra tuvo la magnitud de una bomba nuclear, lo que plantea la siguiente cuestión, ¿seguro que las guerras no contaminaban?

Las Islas Marshall y el nivel del mar:

```
library(leaflet)
datos_radioactividad <- read.table("Lugares y coordenadas.txt", header = TRUE, sep =
→ ",", encoding = "UTF-8")
datos_radioactividad <- datos_radioactividad%>%mutate(popup_info =
→ paste("Localización",":",Localización, "<br/>", "País",":", País, "<br/>", "Causa",":",
→ "radioactividad",":", Causa.Radioactividad, "<br/>"))
mapa <- leaflet()%>% addTiles()
mapa <- mapa%>%addMarkers(data = datos_radioactividad, lat = ~Lat, lng = ~Long, popup
→ = ~popup_info )
```

Las bombas atómicas que sobrevolaron Japón, fueron uno de los últimos capítulos de la Segunda Guerra Mundial. Sin embargo, el desarrollo de las armas nucleares fue una de las disputas internas por la que competían los países. Bajo esta premisa llegó la desgracia a las Islas Marshall. Durante un período entre 1946 y 1958 Estados Unidos hizo pruebas en este archipiélago, por aquel entonces territorio dependiente de los Estados Unidos, llegando a detonar una bomba de hidrógeno cuya potencia podría ser 1000 veces mayor que la de Hiroshima que finalizó la guerra.

Hoy en día, las Islas Marshall son un Estado independiente pero siguen poseyendo un legado de los estadounidenses. En nuestro mapa de radioactividad figuran estas islas, cuanto más nos acercamos más se puede apreciar el problema, que reside en una estructura llamada “Runit Dome” o “Domo de Runit” en español. La isla de Runit alberga esta cúpula en medio de un paisaje paradisíaco, a la vez que desalentador, donde residen cerca de 73000 metros cúbicos de residuos nucleares que dejaron las pruebas del ejército estadounidense. Tal vez, este apartado no tenga una aparente relación con nuestro tópico de las estadísticas y las emisiones de CO₂, sin embargo, nos lleva directos a nuestro siguiente tema a tratar, el nivel del mar.

El mapa interactivo se podrá consultar en la página web anexa al trabajo.


El nivel del Mar:

La cúpula de Runit (Atolón Enetewak) fue fabricada en 1970 tras más de 4 años de recolección de materiales y desechos radioactivos, que causaron la contaminación de sus costas así como dejó solo 4 islas habitables. En 2013 se descubrió que el material de la cúpula se estaba agrietando que podrían derivar en filtraciones hacia el océano, y lo que más preocupa, la mayor elevación del atolón es de 5 metros.

https://ourworldindata.org/explorers/climate-change?facet=none&country=~OWID_WRL&Metric=Sea+level+rise&Long-run+series%3F=false

A continuación, voy a introducir un data set que nos ayudará a entender la magnitud del problema:

```
nivel_del_mar <- read.csv("Nivel del Mar.csv", header = TRUE, sep = ",")
plot(nivel_del_mar$sea_level_rise_average, ylab = "Media subida nivel del mar", main =
  ↳ "Subida nivel del mar con la evolución del tiempo")
```



Este dataset contiene el crecimiento del nivel del mar en dataset creado con datos de Church & White y la Universidad de Hawaii. Las emisiones de CO2 son una de las principales causas del calentamiento global que deriva en un incremento del nivel del mar. En este he usado simplemente la función plot de R básico. A continuación voy a reordenar los datos para obtener un data frame más pequeño con dos columnas que representen fechas y el crecimiento del nivel del mar.

```
seleccion <- c("sea_level_rise_average")
nivel_del_mar_reducido <- select(nivel_del_mar, seleccion)
```

Note: Using an external vector in selections is ambiguous.

```
## i Use `all_of(seleccion)` instead of `seleccion` to silence this message.  
## i See <https://tidyselect.r-lib.org/reference/faq-external-vector.html>.  
## This message is displayed once per session.
```


```
max(nivel_del_mar_reducido$sea_level_rise_average)
```

```
## [1] 68.81163
```

```
Fecha = as.Date(nivel_del_mar$Day)  
nivel_del_mar_reducido <- nivel_del_mar_reducido %>% add_column(Fecha = Fecha)  
ggplot(data = nivel_del_mar_reducido) + geom_point(mapping = aes(y =  
  ↪ sea_level_rise_average, x = Fecha), col = "blue4") + xlab("Años") +  
  ↪ ylab("Crecimiento nivel del mar") + ggtitle("Subida nivel del mar con avance del  
  ↪ tiempo") + geom_smooth(aes(y = sea_level_rise_average, x = Fecha))
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

Subida nivel del mar con avance del tiempo



En el code chunk anterior, hemos añadido una gráfica con ggplot2 así como hemos transformado la columna de las fechas con `as.date` para poder crear la gráfica con el eje x legible. Ahora, vamos a calcular el crecimiento de 2000 a 2020:

```
año2000 <- filter(nivel_del_mar_reducido, Fecha == "2000-10-15")  
año2020 <- filter(nivel_del_mar_reducido, Fecha == "2020-10-15")  
año2020$sea_level_Average
```

```
## NULL
```

```
61.74304 + -(3.5678)
```

```
## [1] 58.17524
```

```
nivel_del_mar_ordenado <-  
↪ nivel_del_mar_reducido[rev(order(as.Date(nivel_del_mar_reducido$Fecha,  
↪ format="%m/%d/%Y"))),]  
  
modelo<-  
↪ lm(nivel_del_mar_ordenado$sea_level_rise_average~nivel_del_mar_ordenado$Fecha)  
modelo
```

```
##  
## Call:  
## lm(formula = nivel_del_mar_ordenado$sea_level_rise_average ~  
##     nivel_del_mar_ordenado$Fecha)  
##  
## Coefficients:  
##             (Intercept)  nivel_del_mar_ordenado$Fecha  
##             -50.129716                0.004508
```

El 15 de octubre del 2000 el nivel del mar estaba por debajo de 0,3 centímetros de crecimiento, mientras en 2020 este estaba sobre los 6.17 centímetros de crecimiento. Entre estas dos medidas podemos concluir que el mar creció en un período de 20 años 5.82 centímetros.

Para tener dos referencias, también he creado un modelo lineal que permite ver la evolución del nivel de crecimiento según el paso de los años. Para ello he empleado la función `lm()` que nos da como resultado la ecuación $0.04508x - 50.129716$. Si consultamos la estructura de nuestro data frame observamos que tenemos 563 filas.

https://en.wikipedia.org/wiki/List_of_countries_by_average_elevation

```
elevación_media <- read.table("Puntos medios por países.txt", header = TRUE, sep =  
↪ ",")  
elevación_media_ordenada <- elevación_media[order(elevación_media$Elevation,  
↪ decreasing = FALSE),]  
head(elevación_media_ordenada)
```

```
##      Country Elevation  
## 89      Maldives      1.5  
## 148      Tuvalu      1.8  
## 18      Botswana    1013  
## 141      Tanzania    1018  
## 130 South Africa    1034  
## 30      Cuba        108
```

El code chunk anterior lee una tabla donde se encuentran los datos de la altura media sobre el nivel del mar de los países.

Si tomamos como medida el crecimiento del mar de 5.82 centímetros en 20 años, se presenta un futuro incierto para países con una altitud que en su mínimo. Con nuestra estimación simple encontramos países como Kiribati, las Maldivas o Tuvalu podrían pasar de ser escenarios paradisíacos a islas sumergidas. La inmersión de esos territorios bajo el mar podría dejar un nuevo problema derivado del cambio climático, la migración masiva.

El problema no solo nos afectaría a nosotros, la principal causa de este crecimiento es la pérdida de hielo de los polos. En el mundo quedan muy pocos lugares con climas tan extremos como el del ártico lo que daría lugar a la pérdida de biodiversidad única en el mundo. Recordemos que los polos especialmente el norte son un atractivo para científicos que durante meses están investigando todo lo relacionado a estos desconocidos territorios, por lo que también saldría perjudicada la ciencia.

La gran industria China:

<https://ourworldindata.org/human-development-index>


<https://data.worldbank.org/indicador/NY.GDP.MKTP.CD>

Antes de introducirnos en el problema del calentamiento global y sus drásticas consecuencias, nos habíamos quedado detenidos tras la Segunda Guerra Mundial. Vamos a continuar con nuestra cronología sobre las emisiones de CO2 para irnos a uno de los grandes países de la actualidad.

Vamos a ver el data frame de las emisiones de CO2 en el caso de China:

```
emisiones_co2_china <- filter(emisiones_anuales_co2, Entity == "China")
gráfico_china_co2 <- ggplot(data = emisiones_co2_china) + geom_line(mapping = aes(x =
↪ Year, y = Annual.CO2.emissions..zero.filled.), col = "blue", lwd = 2) + xlab("Años")
↪ + ylab("Emisión de CO2") + ggtitle("Emisión de CO2 en China")
gráfico_china_co2
```

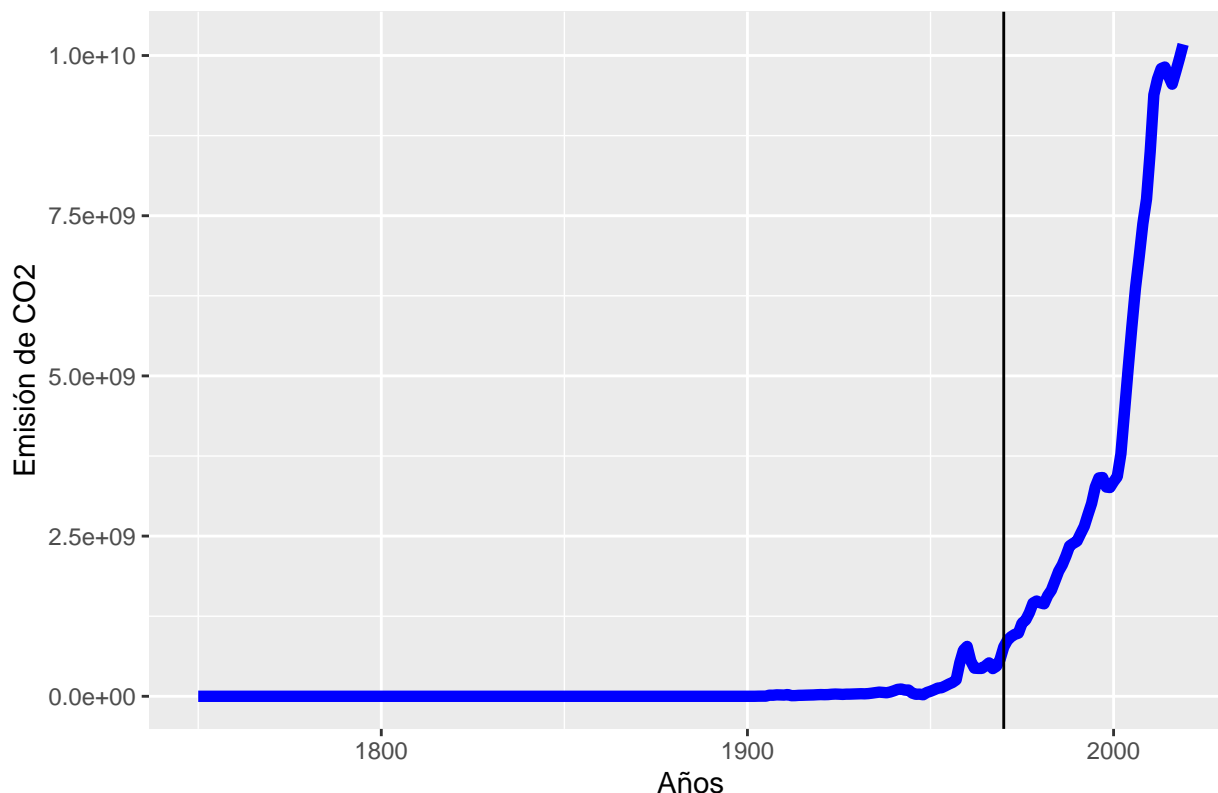
Emisión de CO2 en China



Como vemos su gráfica es muy distante a las gráficas de países que hemos estudiado anteriormente como Reino Unido o España. El crecimiento de las emisiones de CO2 en China se produce justo en 1970, como podemos ver en la siguiente gráfica:

```
gráfico_china_co2 + geom_vline(xintercept = 1970)
```

Emisión de CO2 en China



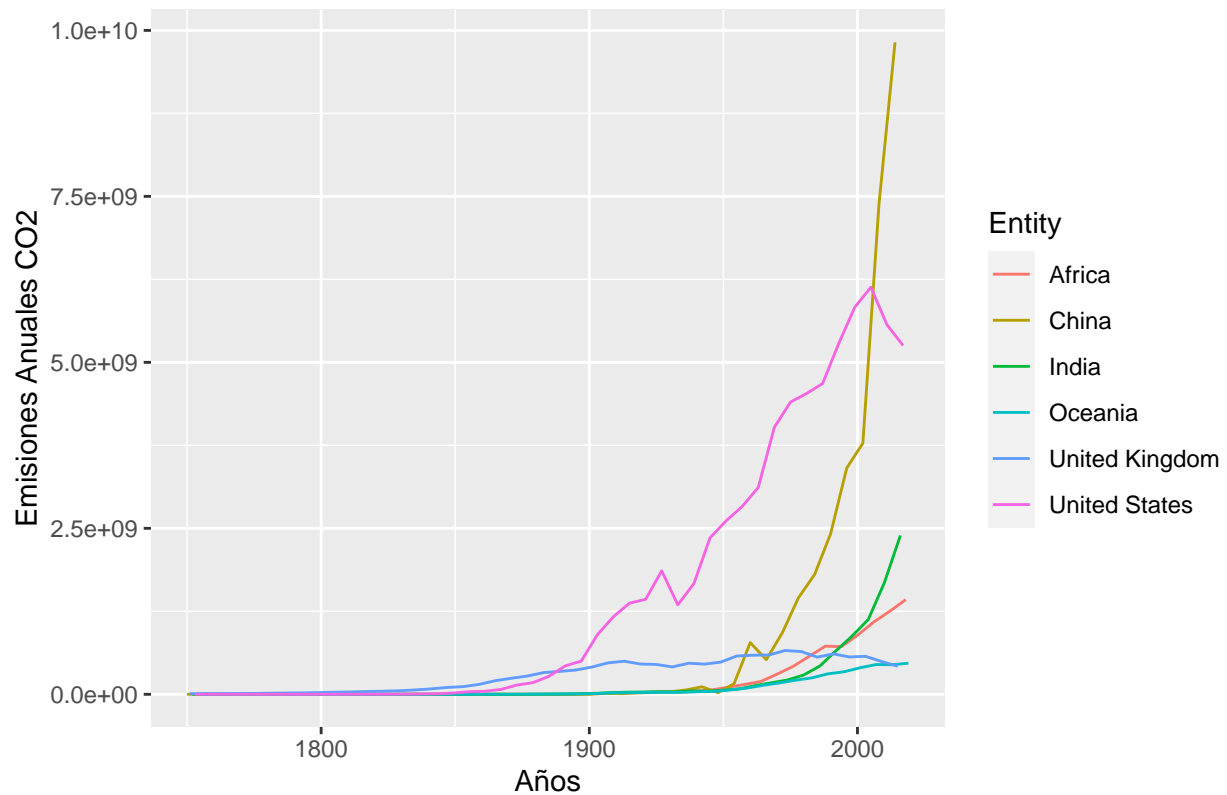
Ese año marcó un antes y un después en la historia del país asiático. En 1949, unos años antes había llegado al poder Mao Zedong, un partidario comunista que crearía la República Popular China. Mao Zedong crearía la llamada Revolución Cultural para preservar el comunismo tras la una gran hambruna que mató a cerca de 30 millones de personas. En 1978 llegaría al poder Deng Xiaoping, que aplicó un programa económico que consistía en la apertura de fronteras, lo que distaba de la idea centralizada de su predecesor. Entre las medidas se animó a maximizar la tierra cultivable para la producción agraria, así creó una industria con cierto control de precios para promover la competitividad. También se crearon zonas con beneficios fiscales para inversiones extranjeras. Otra de las claves fue su apertura al mundo, ingresando en el Banco Mundial y el Fondo Monetario Internacional. Todo este desarrollo tan fugaz produce una gran cantidad de emisiones como podemos observar.

<https://ourworldindata.org/data-review-air-pollution-deaths>

Si comparamos la gráfica de China con la de otras potencias, podemos deducir el ritmo al que trabaja China.

```
países <- c("China", "United Kingdom", "India", "United States", "Africa", "Oceania")
datos_china_y_otros_países <- filter(emisiones_anuales_co2, Entity == países)
gráfica_china_y_otros_países <- ggplot(data = datos_china_y_otros_países) +
  geom_line(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled., col =
  ↪ Entity)) + xlab("Años") + ylab("Emisiones Anuales CO2") + ggtitle("Evolución
  ↪ emisiones de CO2")
gráfica_china_y_otros_países
```

Evolución emisiones de CO2



Como vemos China supera a todos los países que son potencias económicas incluso a continentes como África y Oceanía por un margen bastante amplio.

La economía China por lo tanto tiene también otra cara de la moneda y es el enorme impacto medioambiental que genera.

```
datos_muertes_aire <- read.csv("pollution-deaths-from-fossil-fuels.csv", header = TRUE,
↪ sep = ",")
```

El code chunk anterior lee una tabla con los datos sobre las muertes causadas por la contaminación del aire por cada cien mil habitantes en 2015. Vamos a observar los datos de China.

```
países <- intersect(emisiones_anuales_co2$Entity, datos_muertes_aire$Entity)

datos_muertes_aire_comunes <- filter(datos_muertes_aire, Entity %in% países)

datos_muertes_aire_china <- filter(datos_muertes_aire, Entity == "China")
datos_muertes_aire_china$Excess.mortality.from.fossil.fuels
```

```
## [1] 1554096
```

```
conjuntos <- c("South and Southeast Asia", "Africa", "World", "Europe", "North
↪ America", "Oceania", "South America")

muerteS_sin_continentes <- filter(datos_muertes_aire_comunes, !Entity %in% conjuntos)
↪
```

```
max(muerteS_sin_continentes$Excess.mortality.from.fossil.fuels)
```

```
## [1] 1554096
```


En el code chunk anterior, he eliminado de nuestros datos sobre las muertes a causa de la contaminación del aire las filas que contenían datos generales sobre continentes y el mundo. Esta modificación es útil para comprobar si China tenía el valor más alto, cosa que se puede comprobar ya que el máximo de nuestros datos de muertes sin recopilaciones de países es igual a las de China, que tuvo un total de 1554096 personas. El segundo motivo para crear estos nuevos datos es para establecer una relación con las emisiones de CO2. Con ese propósito vamos a usar la misma técnica sobre el data frame de las emisiones de CO2 para también filtrar por el año 2015 y eliminando los conjuntos de países.

```
emisiones_co2_sincontinentes <- filter(emisiones_anuales_co2, Entity %in% países, Year ==  
→ 2015)
```

Ya tenemos nuestros datos preparados, para hallar los países en común he empleado la función `intersect` que devuelve los valores comunes entre las columnas `Entity` de ambos data frames. A continuación vamos a representarlos gráficamente.

```
aire_emisiones <- data.frame(c(emisiones_co2_sincontinentes$Entity),  
→ c(emisiones_co2_sincontinentes$Annual.CO2.emissions..zero.filled.),  
→ c(datos_muertes_aire_comunes$Excess.mortality.from.fossil.fuels))  
  
colnames(aire_emisiones) <- c("Entity", "Emisiones", "Muertes")  
  
boxplot_con_outliers<- ggplot(data = aire_emisiones) + geom_boxplot(mapping = aes(x =  
→ Muertes, y = Emisiones)); boxplot_con_outliers
```

```
## Warning: Continuous x aesthetic -- did you forget aes(group=...)?
```





```

boxplot_Sin_outliers <- ggplot(data = aire_emisiones) + geom_boxplot(mapping = aes(x =
↪ Muertes, y = Emisiones), outlier.shape = NA); boxplot_Sin_outliers

```

Warning: Continuous x aesthetic -- did you forget aes(group=...)?




He creado primero dos boxplots para resaltar que los datos son muy distantes. Recordemos que en este dataframe agrupamos a la vez tanto grandes potencias como China, como pequeños países como Andorra. Por lo tanto al buscar outliers nos aparece una simple y fina raya como boxplot. Para solventar esta característica usaré límites para nuestro ggplot.

```
gráfica_aire_emisiones <- ggplot(data = aire_emisiones) + geom_point(mapping = aes(x
↪ = Muertes, y = Emisiones)) + xlim(0, 750) + ylim(0,1000000) + ggtitle("Emisiones
↪ Muertes por contaminación en el aire"); gráfica_aire_emisiones
```

```
## Warning: Removed 157 rows containing missing values (geom_point).
```

Emisiones Muertes por contaminación en el aire



Para este plot he decidido estrechar tanto el límite del rango de las muertes en 750 y el el de las emisiones en 1000000. Esto se ha hecho a base de comprobar distintos límites. Aún con límites reducidos, sigue siendo difícil ver alguna relación. Por ello, vamos a reducir a un más nuestro espectro y es que a simple vista la mayoría de los puntos están comprendidos en un entre los 750000 de emisiones y alrededor de las 100 muertes.


```
gráfica_reducida <- gráfica_aire_emisiones + xlim(0, 100) + ylim(0, 750000);  
↪ gráfica_reducida
```

```
## Scale for 'x' is already present. Adding another scale for 'x', which will  
## replace the existing scale.
```

```
## Scale for 'y' is already present. Adding another scale for 'y', which will  
## replace the existing scale.
```

```
## Warning: Removed 166 rows containing missing values (geom_point).
```


Emisiones Muertes por contaminación en el aire



En esta gráfica ya podemos ver una relación más clara, y es que, efectivamente a medida que crecen las emisiones también lo hacen las muertes. Vamos a crear un modelo lineal para comprobarlo.

```
gráfica_aire_emisiones_conlm <- gráfica_reducida + geom_smooth(mapping = aes(x =  
↪ Muertes, y = Emisiones, method = "lm")); gráfica_aire_emisiones_conlm
```

Emisiones Muertes por contaminación en el aire



```
modelo_aire_emisiones <- lm(aire_emisiones$Muertes~aire_emisiones$Emisiones)
modelo_aire_emisiones
```

```
##
## Call:
## lm(formula = aire_emisiones$Muertes ~ aire_emisiones$Emisiones)
##
## Coefficients:
##          (Intercept)  aire_emisiones$Emisiones
##          -3.564e+03      1.029e-04
```

Como vemos sigue un modelo lineal que nos confirma nuestra hipótesis, además, sigue una ecuación igual a $-3.564 * 10^3 + (1.029 * 10^{-4})x$.

Conclusiones apartado emisiones y muertes:

- Como ya imaginábamos, las muertes crecen a la vez que las emisiones, aunque a un ritmo menor. Para apreciar esta característica tenemos que estudiar un grupo de países muy concretos que tengan datos no muy distantes.
- Hay grandes desigualdades respecto a las emisiones y muertes en el mundo, no se podía apreciar un boxplot claramente, aún quitando los outliers. Esto se debe a lo que comentábamos anteriormente, existen países pequeños que no produce tanto, y por consiguiente no presentan tantas muertes. Por otro lado, existen países como China que presentan unas emisiones y muertes mucho mayores.

- Para analizar correctamente, tenemos que usar conjuntos de muestras más próximas entre sí, que facilitan la interpretación de los datos y la visualización de modelos.

Entre más riqueza, mayor contaminación:

Uno de los objetivos de este trabajo era aclarar si existía una relación clara entre riqueza y emisiones de CO2. Para ello vamos a tomar dos alternativas, primero vamos a tomar como referencia el Producto Interior Bruto. El Producto Interior Bruto de un país (PIB) se define como los ingresos que recibe dicho país por los servicios y bienes prestados.

Primero, vamos a leer nuestra tabla:


<https://ourworldindata.org/economic-growth>

```
datos_PIB <- read.csv("gdp-per-capita-maddison-2020.csv", header = TRUE, sep = ",")
head(datos_PIB)
```

```
##      Entity Code Year GDP.per.capita X145446.annotations
## 1 Afghanistan AFG 1950           1156
## 2 Afghanistan AFG 1951           1170
## 3 Afghanistan AFG 1952           1189
## 4 Afghanistan AFG 1953           1240
## 5 Afghanistan AFG 1954           1245
## 6 Afghanistan AFG 1955           1246
```


Si llamamos a la función `head()`, podemos ver como esta distribuido nuestro data frame. La columna `entity` al igual que en data frames anteriores contiene el nombre del país, la columna `code` contiene un código que hace referencia al nombre del país, la columna `year` hace referencia al año de la muestra y por último la columna más relevante, el GDP, que es la que hace referencia al producto Interior Bruto por persona. En este caso, eliminaremos la última columna. Vamos primero a hacer el recorrido del PIB de un país de nuestra muestra como Afganistán, que no es uno de los países que nos vengan a la cabeza en cuanto hablamos de grandes economías.

```
datos_PIB_afg <- filter(datos_PIB, Entity == "Afghanistan")
gráfica_afg <- ggplot(data = datos_PIB_afg) + geom_line(mapping = aes(x = Year, y =
↪ GDP.per.capita), col = "red") + xlab("Años") + ylab("PIB per cápita"); gráfica_afg
```



En este caso, la gráfica de Afganistán no representa un incremento tan claro como en la gráfica de las emisiones o la de la industria. Desde 1960 hasta avanzada la década de los 80 el PIB se mantuvo estable, sin embargo, Afganistán entró en una guerra en 1978 y sus consecuencias llegarían en este entonces. La victoria de los talibanes en esta guerra provocó la entrada de Estados Unidos al país con lo que se creó una de las mayores amenazas mundiales, el terrorismo. Volviendo a nuestros datos, el crecimiento no es tan elevado como en otras gráficas, y es que, se mueve entre los 500 y 2000 dólares de PIB per cápita. Vamos a comprobarlo con un país que sea considerado rico como Alemania:

```
datos_PIB_ger <- filter(datos_PIB, Entity == "Germany")
gráfica_ger <- ggplot(data = datos_PIB_ger) + geom_line(mapping = aes(x = Year, y =
↪ GDP.per.capita), col = "red") + xlab("Años") + ylab("PIB per cápita"); gráfica_ger
```



En el caso de Alemania contamos con más datos y al contrario que en Afganistán si nos centramos sobre el año 1950 encontramos un crecimiento exponencial tras recuperarse de la Segunda Guerra Mundial, llegando desde los 5000 dólares a los más de 40000 de PIB per cápita.

Estas comparaciones son para demostrar que la economía de los países fluctúa y no podemos deducir un crecimiento fijo para todos como en las emisiones de CO2. Por ello vamos a realizar una comparación entre dos años distintos. Primero vamos a ver como están relacionadas las emisiones de CO2 con el PIB per cápita. Primero tomemos medidas de 1950:

```


PIB_pc1950 <- filter(datos_PIB, Year == 1950)
países1950 <- intersect(PIB_pc1950$Entity, emisiones_anuales_co2$Entity)
emisiones_1950 <- filter(emisiones_anuales_co2, Year == 1950 & Entity %in% países1950)
PIB_pc1950 <- filter(PIB_pc1950, Entity %in% países1950)

datos_PIB_emisiones_1950 <- data.frame(c(PIB_pc1950$Entity),
↪ c(PIB_pc1950$GDP.per.capita), c(emisiones_1950$Annual.CO2.emissions..zero.filled.))

colnames(datos_PIB_emisiones_1950) <- c("Entity", "PIB", "Emisiones")

gráfica_PIB_emisiones_1950 <- ggplot(data = datos_PIB_emisiones_1950) +
↪ geom_point(mapping = aes(x = PIB, y = Emisiones)); gráfica_PIB_emisiones_1950


```

Al igual que en el apartado anterior vamos a tener que aplicar unos límites para obtener una visión óptima de la relación. Si nos fijamos en la gráfica encontramos que los valores se encuentran entre los 5000 de PIB per cápita y las emisiones por debajo 5000000.

```
gráfica1950_reducida <- gráfica_PIB_emisiones_1950 + xlim(0, 5000) + ylim(0, 5000000);
→ gráfica1950_reducida
```

```
## Warning: Removed 48 rows containing missing values (geom_point).
```



Con los límites aplicados sobre los 15000 dólares de PIB per cápita y 5000000 de toneladas de emisiones de CO2 no se aprecia ninguna relación, es más, la mayor parte de las muestras se encuentran en unos niveles de emisión bajísimos. Vamos a emplear nuestro modelo lineal para comprobar una relación.

```
gráfica1950_reducida + geom_smooth(data = datos_PIB_emisiones_1950, aes(x = PIB, y =
↪ Emisiones, method = "lm"))
```


```
## Warning: Ignoring unknown aesthetics: method
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

```
## Warning: Removed 48 rows containing non-finite values (stat_smooth).
```

```
## Warning: Removed 48 rows containing missing values (geom_point).
```


```
## Warning: Removed 2 rows containing missing values (geom_smooth).
```



```
gráfica_PIB_emisiones_1950 + geom_smooth(data = datos_PIB_emisiones_1950, aes(x = PIB,
↪ y = Emisiones, method = "lm"))
```

Warning: Ignoring unknown aesthetics: method

`geom_smooth()` using method = 'loess' and formula 'y ~ x'



Nuestro modelo lineal nos indica que no existe un crecimiento entre PIB per cápita y las emisiones de un país, es más parece estable tanto en la gráfica reducida como en la completa. Esto nos indica que en 1950 no existían un gran número de emisiones y la economía de los países tal ve no dependía tanto de los países. Incluso, al final de nuestro modelo lineal encontramos que el modelo lineal presenta una pequeña curva descendente lo que indica que los países con más PIB per cápita tenían un menor nivel de emisiones.

Vamos a repetir la prueba anterior con los datos de 2018 que es el último año de los datos de el data frame de PIB per cápita:

```

PIB_pc2018 <- filter(datos_PIB, Year == 2018)
países2018 <- intersect(PIB_pc2018$Entity, emisiones_anuales_co2$Entity)
emisiones_2018 <- filter(emisiones_anuales_co2, Year == 2018 & Entity %in% países2018)
PIB_pc2018 <- filter(PIB_pc2018, Entity %in% países2018)


datos_PIB_emisiones_2018 <- data.frame(c(PIB_pc2018$Entity),
↪ c(PIB_pc2018$GDP.per.capita), c(emisiones_2018$Annual.CO2.emissions..zero.filled.))

colnames(datos_PIB_emisiones_2018) <- c("Entity", "PIB", "Emisiones")

gráfica_PIB_emisiones_2018 <- ggplot(data = datos_PIB_emisiones_2018) +
↪ geom_point(mapping = aes(x = PIB, y = Emisiones)) + ggtitle(" Emisiones PIB per
↪ cápita"); gráfica_PIB_emisiones_2018

```

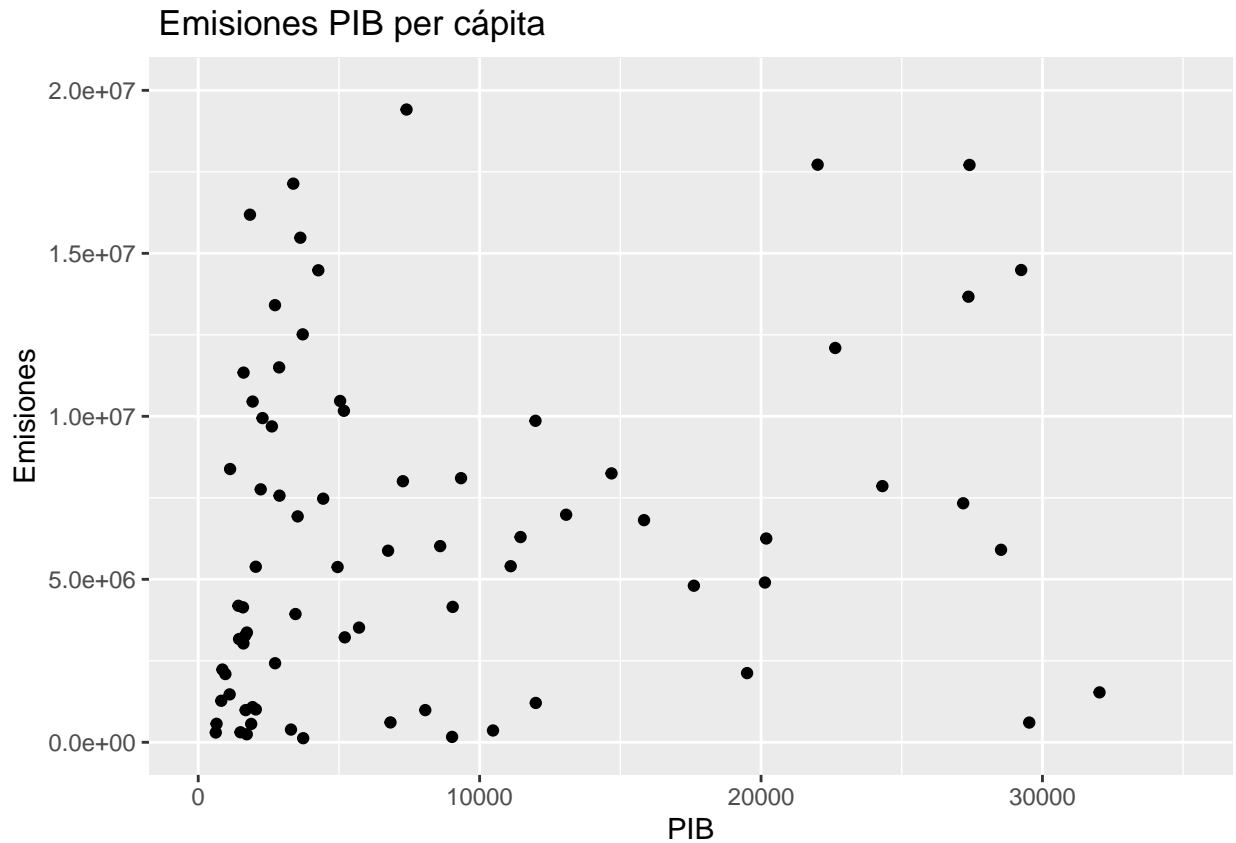
Emisiones PIB per cápita



Volvemos a aplicar límites a nuestra gráfica para intentar relacionar ambas variables:

```
gráfica2018_reducida <- gráfica_PIB_emisiones_2018 + xlim(0, 35000) + ylim(0,  
↪ 20000000); gráfica2018_reducida + ggtitle(" Emisiones PIB per cápita")
```

```
## Warning: Removed 92 rows containing missing values (geom_point).
```



Vamos a aplicar nuestro modelo lineal sobre esta gráfica, a primera vista parece distinta a la de 1950, en este si parece un que a medida que avanza el PIB se incrementan las emisiones.

```
gráfica2018_reducida + geom_smooth(data = datos_PIB_emisiones_2018, aes(x = PIB, y =
↪ Emisiones, method = "lm"))
```


```
## Warning: Ignoring unknown aesthetics: method

## `geom_smooth()` using method = 'loess' and formula 'y ~ x'

## Warning: Removed 92 rows containing non-finite values (stat_smooth).

## Warning: Removed 92 rows containing missing values (geom_point).
```

Emissiones PIB per cápita




```
gráfica_PIB_emisiones_2018 + geom_smooth(data = datos_PIB_emisiones_2018, aes(x = PIB,  
↪ y = Emissiones, method = "lm"))
```

```
## Warning: Ignoring unknown aesthetics: method
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

Emisiones PIB per cápita



El modelo lineal parece similar al anterior con una curva muy estable, sin embargo en este caso los países con menor PIB per cápita presenta una diferencia de emisiones con los países en los que el PIB per cápita es mayor a 5000 dólares. A partir de los 5000 dólares las emisiones de CO2 se estabilizan.

Conclusiones:

- Antes de que las emisiones de CO2 se dispararán, la relación entre el PIB y las emisiones no estaba tan marcada. Tanto los países “ricos” como los “pobres” mantienen similares niveles de emisión de CO2.
- En la actualidad, los países con menor PIB presentan un menor nivel de emisión de CO2. Hasta los 5000 dólares de PIB per cápita, encontramos un crecimiento continuo, a partir de esa cifra las emisiones de CO2 se mantiene estables.

Relación Emisiones e Índice de Desarrollo Humano:

El Índice de Desarrollo Humano mide la calidad de vida en un país, vamos primero a leer una tabla donde se encuentran el IDH de algunas naciones:

```
datos_IDH <- read.csv("human-development-index.csv", header = TRUE, sep = ",")
head(datos_IDH)
```

```
##      Entity Code Year Human.Development.Index..UNDP.
## 1 Afghanistan  AFG 1980                        0.228
## 2 Afghanistan  AFG 1985                        0.273
```



```
## 3 Afghanistan AFG 2002 0.373
## 4 Afghanistan AFG 2003 0.383
## 5 Afghanistan AFG 2004 0.398
## 6 Afghanistan AFG 2005 0.408
```

En este data frame se encuentran almacenados los índices de ciertos países, hay que tener en cuenta que no es homogéneo ya que no hay la misma cantidad de muestras para cada país. Como es habitual, la columna Entity nos da el país al que hace referencia la fila, el código es una abreviatura del nombre del país, year es el año al que referencian los datos y el IDH viene especificado en la última columna.

Antes de comenzar nuestro análisis debemos tener claro como se mide el IDH. El Índice de Desarrollo Humano se mide entre el 0 (menor) y el 1 (mayor). Se puede concluir una clasificación con 4 tipos basados en la puntuación anterior, se considera IDH muy alto ente 1 y 0,8, alto entre 0,799 y 0,7, medio entre 0,699 y 0,550, y bajo entre 0,549 y 0,350.

Bajo estas premisas vamos a realizar un ejercicio muy similar al anterior. Vamos a buscar la relación entre IDH y emisiones en 2 años distintos, emplearemos 1985 y 2020.


```
IDH_1985 <- filter(datos_IDH, Year == 1985)
países1985 <- intersect(IDH_1985$Entity, emisiones_anuales_co2$Entity)
emisiones_1985 <- filter(emisiones_anuales_co2, Year == 1985 & Entity %in% países1985)
IDH_1985 <- filter(IDH_1985, Entity %in% países1985)

datos_IDH_emisiones_1985 <- data.frame(c(IDH_1985$Entity),
→ c(IDH_1985$Human.Development.Index..UNDP.),
→ c(emisiones_1985$Annual.CO2.emissions..zero.filled.))

colnames(datos_IDH_emisiones_1985) <- c("Entity", "IDH", "Emisiones")

gráfica_IDH_emisiones_1985 <- ggplot(data = datos_IDH_emisiones_1985) +
→ geom_point(mapping = aes(x = IDH, y = Emisiones)) + ylim(0, 100000000);
→ gráfica_IDH_emisiones_1985
```

```
## Warning: Removed 19 rows containing missing values (geom_point).
```



Para la gráfica he aplicado directamente un límite para poder tener un conjunto de datos más concentrado y observar mejor las diferencias. A simple vista las mayores emisiones de CO2 se localizan en los IDH mayores. Vamos a utilizar el modelo lineal de nuestro IDH.

```
gráfica_IDH_emisiones_1985 + geom_smooth(data = datos_IDH_emisiones_1985, mapping =
↪ aes(x = IDH, y = Emisiones, method = "lm")) + ggtitle("Emisiones IDH 1985")
```

```
## Warning: Ignoring unknown aesthetics: method
```


```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

```
## Warning: Removed 19 rows containing non-finite values (stat_smooth).
```

```
## Warning: Removed 19 rows containing missing values (geom_point).
```

```
## Warning: Removed 2 rows containing missing values (geom_smooth).
```

Emisiones IDH 1985



Con nuestro modelo lineal aplicado sobre nuestra gráfica encontramos un incremento en las emisiones según avanzamos por los valores del IDH. Por lo tanto, podríamos partir de que a mayor IDH, mayor contaminación. Vamos a corroborar esta premisa con los datos de la actualidad.

```
IDH_2017 <- filter(datos_IDH, Year == 2017)
países2017 <- intersect(IDH_2017$Entity, emisiones_anuales_co2$Entity)
emisiones_2017 <- filter(emisiones_anuales_co2, Year == 2017 & Entity %in% países2017)
IDH_2017 <- filter(IDH_2017, Entity %in% países2017)

datos_IDH_emisiones_2017 <- data.frame(c(IDH_2017$Entity),
  ↪ c(IDH_2017$Human.Development.Index..UNDP.),
  ↪ c(emisiones_2017$Annual.CO2.emissions..zero.filled.))

colnames(datos_IDH_emisiones_2017) <- c("Entity", "IDH", "Emisiones")


gráfica_IDH_emisiones_2017 <- ggplot(data = datos_IDH_emisiones_2017) +
  ↪ geom_point(mapping = aes(x = IDH, y = Emisiones)) + ylim(0, 1000000000);
  ↪ gráfica_IDH_emisiones_2017 + geom_smooth(data = datos_IDH_emisiones_2017, mapping =
  ↪ aes(x = IDH, y = Emisiones), method = "lm") + ggtitle("Emisiones e IDH en 2017")

## `geom_smooth()` using formula 'y ~ x'

## Warning: Removed 5 rows containing non-finite values (stat_smooth).

## Warning: Removed 5 rows containing missing values (geom_point).
```

```
## Warning: Removed 17 rows containing missing values (geom_smooth).
```



En la actualidad la tendencia parece similar a la que calculamos anteriormente, las emisiones siguen aumentando a medida que lo hace el IDH.

Antes de mostrar las conclusiones vamos a encontrar otra forma de ver el problema:


```
datos_IDH_con_nivel <- datos_IDH_emisiones_2017 %>%  
  mutate(Nivel = case_when(  
    0.349 < IDH & IDH <=0.549 ~ "Bajo",  
    0.549 < IDH & IDH <=0.699 ~ "Medio",  
    0.699 < IDH & IDH <=0.799 ~ "Alto",  
    0.799 < IDH & IDH <1 ~ "Muy alto"  
  ))
```

El code chunk anterior crea una nueva columna llamada Nivel que indica el nivel del Índice del IDH, a estas columnas se le añaden valores en función de el rango en el que se encuentra el valor del IDH, según los rangos de niveles del IDH especificados anteriormente.

A continuación, vamos a realizar un boxplot para ver el rango de las emisiones en función del nivel:

```
boxplot_IDH <- ggplot(data = datos_IDH_con_nivel) + geom_boxplot(mapping = aes(x =  
  ↪ IDH, y = Emisiones))  
boxplot_IDH + aes(col = Nivel) + ylim(0, 20000000) + ggtitle("Boxplot niveles de  
  ↪ emisión según nivel de IDH")
```

```
## Warning: Removed 85 rows containing non-finite values (stat_boxplot).
```



En este boxplot observamos un dato adicional, que es que al parecer el grupo con nivel alto presenta una media más baja que incluso el grupo bajo. Por lo que podemos decir que del nivel bajo al medio las emisiones crecen, mientras que del medio al alto se produce una caída, por último del alto al muy alto se produce una escalada en las emisiones que supera los niveles alcanzados anteriormente en el nivel medio.

Conclusiones:

- Las emisiones de CO₂ y el IDH están estrechamente vinculados, los países con mayor calidad de vida, por lo general, tienen un mayor nivel de emisiones de CO₂ que los países situados en los IDH bajos.
- Con el análisis de nuestro boxplot, podemos afirmar que ese crecimiento no es fijo en términos de media total de cada nivel, el nivel alto presenta unas emisiones menores que el nivel bajo, sin embargo, las emisiones siguen creciendo hasta el nivel muy alto.

Relación emisiones y temperatura:

En este apartado realizaremos una comparación entre las emisiones y la temperatura global, que como ya vimos antes está causando que el nivel del mar crezca poniendo en peligro territorios como Kiribati o las Maldivas que poseen elevaciones medias de menos de 2 metros. Para empezar, vamos a cargar nuestro data frame con los datos del crecimiento anual de la temperatura:

<https://ourworldindata.org/grapher/temperature-anomaly?country=~Global>

```
datos_temperatura <- read.csv("temperature-anomaly.csv", header = TRUE, sep = ",")
str(datos_temperatura)
```

```
## 'data.frame': 680 obs. of 6 variables:
## $ Entity : chr "World" "World" "World" "World" ...
## $ Code : logi NA NA NA NA NA NA ...
## $ Year : int 1850 1851 1852 1853 1854 1855 1856 1857 1858 ...
## $ Median.temperature.anomaly.from.1961.1990.average: num -0.373 -0.218 -0.228 -0.269 -0.248 -0.272 ...
## $ Upper.bound..95..CI. : num -0.339 -0.184 -0.196 -0.239 -0.218 -0.241 ...
## $ Lower.bound..95..CI. : num -0.425 -0.274 -0.28 -0.321 -0.301 -0.324 ...
```

Hemos guardado en la variable `datos_temperatura` nuestros datos sobre la variación de la temperatura. Es un data frame con 5 columnas, la primera de ellas como siempre es `Entity`, en este caso en `Entity` solo nos interesa el valor de `world`. La segunda columna es una columna llena de `NA`'s por lo que vamos a omitirla, la tercera es una media de la subida de la temperatura. Las otras dos columnas no las voy a emplear, ya que expresan intervalos de confianza para la recta de regresión lineal aplicada sobre la temperatura.


Al igual que en los ejercicios anteriores

```
av_temperatura <- filter(datos_temperatura, Entity == "World")
años <- intersect(datos_temperatura$Year, emisiones_anuales_co2$Year)
emisiones_globales <- filter(emisiones_anuales_co2, Entity == "World" & Year %in% años)
temperatura_global <- filter(av_temperatura, Year %in% años)

temperatura_emisiones <-
→ data.frame(c(temperatura_global$Year), c(temperatura_global$Median.temperature.anomaly.from.1961.1990.average),
→ c(emisiones_globales$Annual.CO2.emissions..zero.filled.))

colnames(temperatura_emisiones) <- c("Year", "Temperatura", "Emisiones")

gráfica_temperatura_emisiones <- ggplot(data = temperatura_emisiones) +
→ geom_point(mapping = aes(x = Temperatura, y =
→ Emisiones)); gráfica_temperatura_emisiones
```




De todas las relaciones que hemos estudiado con las emisiones, esta tiene un crecimiento gradual muy claro entre ambas variables, vamos a aplicar el modelo lineal para certificar la relación:

```
gráfica_temperatura_emisiones + geom_smooth(data = temperatura_emisiones, mapping =
→ aes(x = Temperatura, y = Emisiones), method = "lm") + ggtitle("Modelo lineal
→ emisiones-temperatura")
```

```
## `geom_smooth()` using formula 'y ~ x'
```

Modelo lineal emisiones-temperatura



Con el modelo lineal anterior podemos deducir que la emisiones han sido un factor clave en la evolución de la temperatura. Además el modelo lineal se ve representado como una recta casi perfecta, lo que puede ser indicativo de que ambas medidas son proporcionales.

Ya vimos que el cambio climático podía afectar a la temperatura, y esta por consiguiente a la subida del nivel del mar en base a la pérdida de hielo de los polos. Este problema no solo llega de lleno a las Islas Marshall, si no que también puede afectar a países menores que no poseen una gran estructura económico. Kiribati es un archipiélago situado en el Océano Pacífico, en la tabla sobre las elevaciones medias vimos que este país estaba en una situación crítica. Si mantenemos este nivel de emisiones muchos perderán su hogar, produciendo una gran crisis migratoria causada por el calentamiento global.

<https://ourworldindata.org/grapher/mass-balance-us-glaciers?country=Gulkana+Glacier~Lemon+Creek+Glacier~South+Cascade+Glacier~Wolverine+Glacier>

```
glaciares_EEUU <- read.csv("mass-balance-us-glaciers.csv")
head(glaciares_EEUU)
```


```
##      Entity Code Year cumulative_mass_balance
## 1 Gulkana Glacier  NA 1965                0.00
## 2 Gulkana Glacier  NA 1966               -0.74
## 3 Gulkana Glacier  NA 1967               -0.56
## 4 Gulkana Glacier  NA 1968               -1.05
## 5 Gulkana Glacier  NA 1969               -2.26
## 6 Gulkana Glacier  NA 1970               -2.31
```



```

gráfica_glaciares <- ggplot(data = glaciares_EEUU) + geom_line(mapping = aes(x =
↳ Year, y = cumulative_mass_balance)) + xlab("Años") + ylab("Balance de masa
↳ glaciares") + ggtitle("Evolución masa glaciares Estados Unidos"); gráfica_glaciares +
↳ aes(col = Entity)

```



Antes de finalizar este apartado vamos a reafirmar la relación entre temperatura y nivel del mar con data frame que contiene datos acerca de glaciares en Estados Unidos desde el año 1965 a 2019, con la masa en formato de metros en equivalente a agua. Si nos fijamos en su estructura la columna Entity contiene el nombre de los glaciares, el código es una columna vacía, otra columna que representa el año, y el balance acumulativo de el equivalente en metro de agua ganada o pérdida.

Si nos fijamos en la gráfica la masa de todos ha decrecido considerablemente desde el año 1960, en gráficas anteriores vimos que por esa fecha España había conseguido ,mejorar su economía y con ello aumentar sus emisiones de CO2, por lo que tal vez las emisiones generaron efectos difícilmente reversibles sobre la mitad del siglo XX.

Para analizar los glaciares en comparación con las emisiones y temperatura vamos a tener que quedarnos con uno de ellos, el glaciar Wolverine, situado en Alaska.

Vamos a realizar un gráfica para compararlo respecto a la temperatura en el período de tiempo estipulado por los datos de los glaciares:

```

datos_temp_1965 <- select(av_temperatura, -c(5, 6))
datos_temp_1965 <- filter(datos_temp_1965, Year >= 1965)
datos_wolverine <- filter(glaciares_EEUU, Entity == "Wolverine Glacier")

glaciares_temp <- data.frame(c(datos_temp_1965$Year),c(datos_wolverine$Entity),
↳ c(datos_temp_1965$Median.temperature.anomaly.from.1961.1990.average),
↳ c(datos_wolverine$cumulative_mass_balance))

```


```

colnames(glaciares_temp) <- c("Año", "Entity", "Temperatura", "Masa")

gráfica_gla_datos <- ggplot(data = glaciares_temp) + geom_point(mapping = aes(y =
↳ Temperatura, x = Masa), col = "purple") + xlab("Masa") + ylab("Temperatura") +
↳ ggtitle("Gráfica relación masa - temperatura"); gráfica_gla_datos +
↳ geom_smooth(mapping = aes(x = Masa, y = Temperatura), method = "lm", formula = y~x)

```

Gráfica relación masa – temperatura



La gráfica corrobora lo que ya imaginábamos, que a con una temperatura superior los glaciares pierden hielo que pasa a convertirse en agua para nuestros océanos, el modelo lineal no abarca todos los puntos, pero muestra una recta con un crecimiento continuo.

Al ser cierta esta relación, también lo será la que relaciona un glaciar con las emisiones, dado que hemos comprobado la relación entre temperatura y emisiones anteriormente.

```

datos EEUU_1965 <- filter(emisiones_anuales_co2, Entity == "United States", Year >=
↳ 1965 & Year < 2020)

eeuu_emi_glac <- data.frame(c(datos EEUU_1965$Year),
↳ c(datos EEUU_1965$Annual.CO2.emissions..zero.filled.),
↳ c(datos_wolverine$cumulative_mass_balance))


colnames(eeuu_emi_glac) <- c("Año", "Emisiones", "Masa")

gráfica_emisiones_eeuu <- ggplot(data = eeuu_emi_glac) + geom_point(mapping = aes(y =
↳ Emisiones, x = Masa)) + xlab("Masa") + ylab("Emisiones de CO2") + ggtitle("Relación
↳ masa - emisiones") + geom_smooth(mapping = aes(x = Masa, y = Emisiones), method =
↳ "lm"); gráfica_emisiones_eeuu

```

```
## `geom_smooth()` using formula 'y ~ x'
```

Relación masa – emisiones



En el caso del análisis de la relación entre emisiones y masa, no existe tanta dependencia como con la temperatura, los valores valores de emisiones de CO₂, no se corresponde a los valores mayores de la masa. En las gráfica de emisiones hemos visto que los países se habían concienciado con el cambio climático desde el 2000, lo que llevo a una etapa de desindustrialización para bajar las emisiones. Conociendo estos datos si la temperatura ha seguido aumentado podríamos concluir que esta depende de otros factores a parte de las emisiones de CO₂, otros de los gases que afectan a la atmósfera y con ello favorecen el calentamiento global son el Óxido Nitroso (N₂O), el metano(CH₄) y el ozono(O₃).

Conclusiones:

Las emisiones de CO₂ han tenido un papel fundamental para el desarrollo del calentamiento global. La temperatura es una de los factores que están provocando la desaparición de los polos, como vemos con los glaciares de Estados Unidos. Esta situación pone en riesgo a un gran número de la población, pese a que solo unos pocos países tienen una elevación media sin embargo, también puede afectar a ciudades, por ejemplo, Alicante tiene una elevación de tiene una altitud media de 0 metros, incluyendo a esta ciudad costera española en la lista de sitios que pueden ser borrados del mapa.

Entre más población, mayores emisiones:

Uno de los objetivos de este trabajo era aclarar si las emisiones pueden depender de la población de un país, por ejemplo, cuando estudiamos el caso de China pudimos concluir que es el país líder mundial en

emisiones. China tiene una inmensa población cercana a los 1400 millones de personas. Para este primer caso se cumpliría nuestra hipótesis de que los países con mayor población son los que más emiten. Aún así, con un solo caso no nos basta, así que tenemos que recabar más datos para juzgar con argumentos basados en nuestros datos.

Primero vamos a leer nuestra tabla sobre los datos de la población mundial:

<https://data.worldbank.org/indicador/SP.POP.TOTL>

```
library(tidyr)
datos_población <- read.table("Population.csv", header = TRUE, sep = ",")
head(datos_población)
```

| ## | | Country.Name | Country.Code | Indicator.Name | Indicator.Code | | |
|------|-----------------------------|--------------|--------------|-------------------|----------------|-----------|-----------|
| ## 1 | | Aruba | ABW | Population, total | SP.POP.TOTL | | |
| ## 2 | Africa Eastern and Southern | | AFE | Population, total | SP.POP.TOTL | | |
| ## 3 | | Afghanistan | AFG | Population, total | SP.POP.TOTL | | |
| ## 4 | Africa Western and Central | | AFW | Population, total | SP.POP.TOTL | | |
| ## 5 | | Angola | AGO | Population, total | SP.POP.TOTL | | |
| ## 6 | | Albania | ALB | Population, total | SP.POP.TOTL | | |
| ## | X1960 | X1961 | X1962 | X1963 | X1964 | X1965 | X1966 |
| ## 1 | 54208 | 55434 | 56234 | 56699 | 57029 | 57357 | 57702 |
| ## 2 | 130836765 | 134159786 | 137614644 | 141202036 | 144920186 | 148769974 | 152752671 |
| ## 3 | 8996967 | 9169406 | 9351442 | 9543200 | 9744772 | 9956318 | 10174840 |
| ## 4 | 96396419 | 98407221 | 100506960 | 102691339 | 104953470 | 107289875 | 109701811 |
| ## 5 | 5454938 | 5531451 | 5608499 | 5679409 | 5734995 | 5770573 | 5781305 |
| ## 6 | 1608800 | 1659800 | 1711319 | 1762621 | 1814135 | 1864791 | 1914573 |
| ## | X1967 | X1968 | X1969 | X1970 | X1971 | X1972 | X1973 |
| ## 1 | 58044 | 58377 | 58734 | 59070 | 59442 | 59849 | 60236 |
| ## 2 | 156876454 | 161156430 | 165611760 | 170257189 | 175100167 | 180141148 | 185376550 |
| ## 3 | 10399936 | 10637064 | 10893772 | 11173654 | 11475450 | 11791222 | 12108963 |
| ## 4 | 112195950 | 114781116 | 117468741 | 120269044 | 123184308 | 126218502 | 129384954 |
| ## 5 | 5774440 | 5771973 | 5803677 | 5890360 | 6041239 | 6248965 | 6497283 |
| ## 6 | 1965598 | 2022272 | 2081695 | 2135479 | 2187853 | 2243126 | 2296752 |
| ## | X1974 | X1975 | X1976 | X1977 | X1978 | X1979 | X1980 |
| ## 1 | 60527 | 60653 | 60586 | 60366 | 60102 | 59972 | 60097 |
| ## 2 | 190800796 | 196409937 | 202205766 | 208193045 | 214368393 | 220740384 | 227305945 |
| ## 3 | 12412960 | 12689164 | 12943093 | 13171294 | 13341199 | 13411060 | 13356500 |
| ## 4 | 132699537 | 136173544 | 139813171 | 143615715 | 147571063 | 151663853 | 155882270 |
| ## 5 | 6761623 | 7023994 | 7279630 | 7533814 | 7790774 | 8058112 | 8341290 |
| ## 6 | 2350124 | 2404831 | 2458526 | 2513546 | 2566266 | 2617832 | 2671997 |
| ## | X1981 | X1982 | X1983 | X1984 | X1985 | X1986 | X1987 |
| ## 1 | 60561 | 61341 | 62213 | 62826 | 63024 | 62645 | 61838 |
| ## 2 | 234058404 | 240999134 | 248146290 | 255530063 | 263161451 | 271050065 | 279184536 |
| ## 3 | 13171679 | 12882518 | 12537732 | 12204306 | 11938204 | 11736177 | 11604538 |
| ## 4 | 160223588 | 164689764 | 169279422 | 173991851 | 178826553 | 183785612 | 188868567 |
| ## 5 | 8640478 | 8952971 | 9278104 | 9614756 | 9961993 | 10320116 | 10689247 |
| ## 6 | 2726056 | 2784278 | 2843960 | 2904429 | 2964762 | 3022635 | 3083605 |
| ## | X1988 | X1989 | X1990 | X1991 | X1992 | X1993 | X1994 |
| ## 1 | 61072 | 61033 | 62152 | 64623 | 68240 | 72495 | 76705 |
| ## 2 | 287524258 | 296024639 | 304648010 | 313394693 | 322270073 | 331265579 | 340379934 |
| ## 3 | 11618008 | 11868873 | 12412311 | 13299016 | 14485543 | 15816601 | 17075728 |
| ## 4 | 194070079 | 199382783 | 204803865 | 210332267 | 215976366 | 221754806 | 227692136 |
| ## 5 | 11068051 | 11454784 | 11848385 | 12248901 | 12657361 | 13075044 | 13503753 |

```
## 6 3142336 3227943 3286542 3266790 3247039 3227287 3207536
## X1995 X1996 X1997 X1998 X1999 X2000 X2001
## 1 80324 83211 85450 87280 89009 90866 92892
## 2 349605660 358953595 368440591 378098393 387977990 398113044 408522129
## 3 18110662 18853444 19357126 19737770 20170847 20779957 21606992
## 4 233807627 240114179 246613750 253302310 260170348 267214544 274433894
## 5 13945205 14400722 14871572 15359600 15866871 16395477 16945753
## 6 3187784 3168033 3148281 3128530 3108778 3089027 3060173
## X2002 X2003 X2004 X2005 X2006 X2007 X2008
## 1 94992 97016 98744 100028 100830 101226 101362
## 2 419223717 430246635 441630149 453404076 465581372 478166911 491173160
## 3 22600774 23680871 24726689 25654274 26433058 27100542 27722281
## 4 281842480 289469530 297353098 305520588 313985474 322741656 331772330
## 5 17519418 18121477 18758138 19433604 20149905 20905360 21695636
## 6 3051010 3039616 3026939 3011487 2992547 2970017 2947314
## X2009 X2010 X2011 X2012 X2013 X2014 X2015
## 1 101452 101665 102050 102565 103165 103776 104339
## 2 504604672 518468229 532760424 547482863 562601578 578075373 593871847
## 3 28394806 29185511 30117411 31161378 32269592 33370804 34413603
## 4 341050537 350556886 360285439 370243017 380437896 390882979 401586651
## 5 22514275 23356247 24220660 25107925 26015786 26941773 27884380
## 6 2927519 2913021 2905195 2900401 2895092 2889104 2880703
## X2016 X2017 X2018 X2019 X2020 X
## 1 104865 105361 105846 106310 106766 NA
## 2 609978946 626392880 643090131 660046272 677243299 NA
## 3 35383028 36296111 37171922 38041757 38928341 NA
## 4 412551299 423769930 435229381 446911598 458803476 NA
## 5 28842482 29816769 30809787 31825299 32866268 NA
## 6 2876101 2873457 2866376 2854191 2837743 NA
```

```
datos_población_para_ordenar <- as_tibble(datos_población)
```


El data frame llamado `datos_población` nos proporciona los datos de la evolución demográfica de cada país desde 1960 a 2020. El data frame contiene una columna con los nombres de los países (`country.name`), otra columna llamada `country.code` con la abreviatura del nombre, otra para indicar la medida que es la población en nuestro caso y el código del propio indicador. Por último, tenemos a diferencia de en nuestros datos anteriores, una columna para cada año. Esto impide puedan ser llamados `tidy` u ordenados ya que tenemos numerosas columnas para representar cada uno de los años. Tenemos que ordenarlos como en los anteriores. Con ese objetivo vamos a emplear el paquete `dplyr` y `tidyr`:

```
borrar <- ("X")
datos_población_para_ordenar <- datos_población_para_ordenar[,
↪ !names(datos_población_para_ordenar) %in% borrar]
names(datos_población_para_ordenar) <- sub("^X", "",
↪ names(datos_población_para_ordenar))
datos_población_ordenados <- gather(datos_población_para_ordenar, "Year", "Population",
↪ -c(1:4))
datos_población_ordenados <-
↪ datos_población_ordenados[order(datos_población_ordenados$Country.Name), ]
```

Para ordenar nuestros datos he usado el comando `gather`, este nos permite crear dos nuevas columnas llamadas `year` y `population`, para contener individualmente el año y la población. Para terminar la reestructuración ordenamos los datos alfabéticamente según el nombre del país.

Ahora ya tenemos unos datos similares a los que habíamos registrado hasta ahora. Primero vamos a observar la tendencia de la población mundial de 1960 a 2020, que es el período que nos presentan nuestros datos:

```
población_mundial <- filter(datos_población_ordenados, Country.Name == "World")
evolución_demográfica_mundial <- ggplot(data = población_mundial)+ geom_point(mapping
↪ = aes(x = as.numeric(Year), y = Population), col =
↪ "Orange");evolución_demográfica_mundial + xlab("Años") + ylab("Población Mundial") +
↪ ggtitle("Evolución Demográfica población mundial")
```




Si nos fijamos la población mundial en los últimos años ha crecido drásticamente, pasando de los 3 mil millones de habitantes, a los casi 8 mil millones de la actualidad. Esto se puede deber a las mejoras económicas y sociales, a las mejoras sanitarias. Estos factores han causado un aumento en la esperanza de vida media de los países, una mayor migración y un aumento en la natalidad. De hecho existen países como China que han querido parar esta tendencia con la imposición de solo poder tener un hijo por familia. Claramente el aumento de la población esta directamente relacionado con el crecimiento de las emisiones, ya que entre más población se generan más puestos de trabajo y un mayor numero de emisiones.

```
library(dplyr)
emisiones_mundiales <- filter(emisiones_anuales_co2, Year >= 1960, Entity == "World")
población_mundial_2019 <- filter(población_mundial, as.numeric(Year) < 2020)
emisiones_población_mundial <- data.frame(c(emisiones_mundiales$Year),
↪ c(población_mundial_2019$Population),
↪ c(emisiones_mundiales$Annual.CO2.emissions..zero.filled.))
colnames(emisiones_población_mundial) <- c("Años", "Población", "Emisiones")
emisiones_población_gráfica <- ggplot(data = emisiones_población_mundial) +
↪ geom_point(mapping = aes(x = Población, y = Emisiones), col = "orange")
```

```
emisiones_población_gráfica + ggtitle("Evolución emisiones junto población") +
↳ geom_smooth(aes(x = Población, y = Emisiones))
```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```



La tendencia de que a mayor población mundial mayores emisiones parece comprobarse con el conjunto del mundo, con un modelo lineal que parece ajustarse perfectamente a los puntos obtenidos. Sin embargo, esto no nos permite confirmar que entre mayor población, mayores emisiones. Para comprobarlo vamos a movernos a un año concreto, en este caso será 2019 ya que es el último año del que tenemos referencias en los datos de las emisiones. Vamos a crear una nueva variable que contenga las emisiones per cápita de cada país.

```
conjuntos_países <- c("Africa", "Europe", "Asia (excl. China & India)", "EU-28",
↳ "EU-27", "Europe (excl. EU-27)", "Europe (excl. EU-28)", "North America", "Oceania",
↳ "South America", "World")
emisiones_2019 <- filter(emisiones_anuales_co2, Year == 2019, !Entity %in%
↳ conjuntos_países)
países_población <- intersect(emisiones_2019$Entity,
↳ datos_población_ordenados$Country.Name)
emisiones_2019 <- filter(emisiones_2019, Entity %in% países_población)
población_2019 <- filter(datos_población_ordenados, Year == 2019, Country.Name %in%
↳ países_población)

emisiones_población_2019 <- data.frame(c(emisiones_2019$Entity),
↳ c(emisiones_2019$Annual.CO2.emissions..zero.filled.), c(población_2019$Population))
```

```

colnames(emisiones_población_2019) <- c("País", "Emisiones", "Población")

emisiones_población_2019 <- emisiones_población_2019 %>%mutate("Emisionespc" =
↳ Emisiones/Población)

```

En el code chunk anterior hemos creado una data frame que contiene los países junto con sus emisiones de CO2, su población en 2019. A este data frame le hemos añadido una columna con la medida de emisiones per cápita. Esta representa las emisiones de CO2 que se corresponden a cada habitante del país en toneladas. Vamos a realizar un plot entre emisiones y emisiones per cápita.

```


gráfica_Emisiones_per_cápita <- ggplot( data = emisiones_población_2019)+
↳ geom_point(mapping = aes(x = Emisiones, y = Emisionespc), col = "pink4")+
↳ ylab("Emisiones per cápita")+ xlab("Emisiones totales");gráfica_Emisiones_per_cápita
↳ + xlim(0, 1000000000)+ ggtitle("Gráfico emisiones totales junto a emisiones per
↳ cápita") + geom_smooth(aes(x = Emisiones, y = Emisionespc));
↳ gráfica_Emisiones_per_cápita

```


```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```

```
## Warning: Removed 5 rows containing non-finite values (stat_smooth).
```

```
## Warning: Removed 5 rows containing missing values (geom_point).
```




```
## Warning: Removed 1 rows containing missing values (geom_point).
```



En la gráfica podemos observar que en valores de emisiones bajos las emisiones per cápita fluctúan, a medida que estas emisiones crecen las emisiones per cápita se van estabilizando. Esta gráfica podría sugerir que no existe una gran relación entre emisiones totales y las emisiones per cápita, de hecho, muchos puntos quedan fuera de nuestro modelo lineal.


Para comprobarlo vamos a ver si a medida que la población crece también lo hacen las emisiones per cápita.

```
gráfica_Emisiones_per_cápita <- ggplot( data = emisiones_población_2019)+  
→ geom_point(mapping = aes(x = Población, y = Emisionespc), col = "pink3")+  
→ ylab("Emisiones per cápita")+ xlab("Población");  
  
gráfica_Emisiones_per_cápita + ggtitle("Gráfico población junto a emisiones per cápita")  
→ + geom_smooth(aes(x = Población, y = Emisionespc), method = "loess", formula = y~x) +  
→ xlim(0, mean(emisiones_población_2019$Población)) + ylim(0, 40)
```

```
## Warning: Removed 1 rows containing non-finite values (stat_smooth).
```

```
## Warning: Removed 1 rows containing missing values (geom_point).
```

Gráfico población junto a emisiones per cápita




```
gráfica_Emisiones_per_cápita + ggtitle("Gráfico población junto a emisiones per cápita")  
  ↪ + geom_smooth(aes(x = Población, y = Emisionespc), method = "loess", formula = y~x) +  
  ↪ xlim(0, 1000000) + ylim(0, 40)
```

```
## Warning: Removed 81 rows containing non-finite values (stat_smooth).
```

```
## Warning: Removed 81 rows containing missing values (geom_point).
```

Gráfico población junto a emisiones per cápita



```
orden_emisiones_pc <-
  ↪ emisiones_población_2019[order(emisiones_población_2019$Emisionespc, decreasing =
  ↪ TRUE),]; head(orden_emisiones_pc)
```

| ## | País | Emisiones | Población | Emisionespc |
|--------|---------------------|-----------|-----------|-------------|
| ## 135 | Qatar | 109344710 | 2832071 | 38.60945 |
| ## 43 | Curacao | 5195804 | 157441 | 33.00159 |
| ## 117 | New Caledonia | 8451602 | 271300 | 31.15224 |
| ## 163 | Trinidad and Tobago | 37863888 | 1394969 | 27.14318 |
| ## 88 | Kuwait | 107532047 | 4207077 | 25.55980 |
| ## 13 | Bahrain | 34354328 | 1641164 | 20.93290 |

Nuestra primera gráfica contiene un rango de poblaciones demasiado amplio por lo que no podemos analizar correctamente nuestro modelo lineal. Para ello he establecido un límite arbitrario que nos permitiera comprender mejor la medida. Como vemos, los valores de las emisiones per cápita se mantienen en un rango de estabilidad a medida que la población va aumentando. Esto nos hace pensar que a mayor población no se cumple que haya mayores emisiones per cápita. Los países en su conjunto tienen emisiones per cápita no muy distantes, es más, los países con menor población son los que acumulan las mayores emisiones per cápita. El país con mayor emisiones per cápita es Catar con una cifra algo menor a los 3 millones de habitantes, su principal fuente de ingresos son los combustibles fósiles, además, es uno de los países con mayor PIB per cápita. La fortuna generada por el petróleo se reparte entre una población pequeña en comparación con otros países, lo que indica que las emisiones generadas por la quema de combustible también alcanzan un valor per cápita muy alto. Los otros 4 países que se colocan en la cima de las emisiones per cápita son Curazao, Trinidad y Tobago, Kuwait y Bahrein, todos ellos relacionados con la industria de los combustibles fósiles y con una población que no supera los 5 millones en ninguno de ellos.

Conclusiones:

- Los países con mayor población generan más emisiones, evidentemente, sin embargo, todos los países presentan unas emisiones per cápita estables lo que indica que el habitante de un país densamente poblado y otro de un país de menor tamaño generan similares toneladas de emisiones de CO2.
- Los países que presentan un mayor número de emisiones per cápita, principalmente son regiones pequeñas que poseen reservas de combustibles fósiles, cuya quema genera muchos ingresos a la vez que emisiones.
- Si comparamos las emisiones totales con las emisiones per cápita, ocurre algo similar a la comparación realizada anteriormente junto a la población. Los países con mayores emisiones tiene emisiones per cápita similares a los que no generan tanto, salvo a aquellos cuya economía se basa en los combustibles fósiles.

Apunte sobre la población y temperatura:


En el apartado de las Islas Marshall y el nivel del mar hicimos referencia a que el incremento oceánico conllevaría consecuencias como una crisis migratoria a causa de territorios sumergidos. Ciertos países como Tuvalu, Kiribati o Las Maldivas se encuentran entre las naciones con menor altitud media, ninguna de ellas supera los dos metros, lo que las sitúa en el foco de este problema. Sin embargo en ellos la población no se ha visto afectada como se observa en la siguiente gráfica:

```
países_riesgo <- c("Kiribati", "Tuvalu", "Maldives")
datos_población_riesgo <- filter(datos_población_ordenados, Country.Name %in%
↪ países_riesgo)

colnames(datos_población_riesgo) <- c("País", "Code", "Indicator", "Ind.code", "Año",
↪ "Población")

gráfica_ev_riesgo <- ggplot(data =datos_población_riesgo) + geom_line(mapping = aes(
↪ x = as.numeric(Año), y = Población)) + xlab("Años") + ylab("Población") +
↪ ggtitle("Evolución población en países en riesgo") + aes(col = País);
↪ gráfica_ev_riesgo
```

Evolución población en países en riesgo




Vemos que el creciente nivel del mar no ha provocado por el momento ninguna crisis migratoria, dado que en los países en riesgo la población sigue creciendo, sin embargo podemos encontrar otra lista de países afectados por el cambio climático a través de los desastres naturales, nuestro siguiente apartado.

Climatología y desastres naturales:

Para empezar este apartado vamos a recurrir al data frame base que hemos estado usando a lo largo de este proyecto el de las emisiones de CO2. Vamos a situarnos en Kuwait, uno de los países con más riquezas del mundo. Kuwait era uno de los países mencionados en el apartado anterior, tiene una pequeña población y unas grandes emisiones de CO2. El país árabe comenzó el siglo XX siendo una colonia británica. En 1991 conseguiría la independencia y ocurría algo más que se ve reflejado en la siguiente gráfica:


```
emisiones_kuwait <- filter(emisiones_anuales_co2, Entity == "Kuwait")
gráfica_kuwait <- ggplot(data = emisiones_kuwait) + geom_line(mapping = aes(x = Year,
↪ y = Annual.CO2.emissions..zero.filled.), col = "purple") + xlab("Años") +
↪ ylab("Emisiones CO2") + ggtitle("Emisiones CO2 en Kuwait"); gráfica_kuwait
```

Emisiones CO2 en Kuwait



```
emisiones_kuwait_incendios <- filter(emisiones_anuales_co2, Entity == "Kuwaiti Oil  
→ Fires")  
→ gráfica_kuwait_incendios <- ggplot(data = emisiones_kuwait_incendios)+  
→ geom_line(mapping = aes(x = Year, y = Annual.CO2.emissions..zero.filled.), col =  
→ "purple3") + ylab("Emisiones CO2") + xlab("Años") + ggtitle("Emisiones CO2 incendios  
→ petróleo Kuwait"); gráfica_kuwait_incendios + xlim(1980, 1995)
```

Warning: Removed 254 row(s) containing missing values (geom_path).



Si nos fijamos Kuwait presenta una evolución de las emisiones de CO2 muy similares a la de los países que estudiamos al principio. Sin embargo, presenta un pequeño matiz que los hace diferente y permitirá introducir nuestro nuevo tema a tratar. En el mismo año de su independencia Kuwait tuvo una guerra con Irán causada por las disputas de las reservas de petróleo. Durante esa guerra Irán provocó un incendio quemando cerca de 700 pozos petrolíferos de Kuwait, eso produjo el desmedido repunte de las emisiones de CO2 que se observan.

Si bien, esto no se considera un desastre natural si representa uno de los comportamientos que se encuentra consolidados en la sociedad de las altas esferas, la avaricia. Las industrias aumentaron las emisiones de CO2 como ya hemos estudiado, sin embargo estas también afecta al clima con las subidas del nivel del mar, la temperatura y los desastres naturales.

<https://ourworldindata.org/natural-disasters>


```
desastres_naturales <- read.csv("number-of-natural-disaster-events.csv", header = TRUE)
head(desastres_naturales)
```

```
##           Entity Code Year Number.of.disasters..EMDAT..2020..
## 1 All natural disasters  NA 1900                      5
## 2 All natural disasters  NA 1901                      2
## 3 All natural disasters  NA 1902                      9
## 4 All natural disasters  NA 1903                      8
## 5 All natural disasters  NA 1904                      2
## 6 All natural disasters  NA 1905                      4
```

El data frame leído anteriormente contiene el número de desastres naturales ocurridos por año desde el año 1900 hasta el 2019. Si accedemos a su función head() podemos comprobar que se encuentra compuesto por

4 columnas. La primera de ellas (Entity) indica el tipo de desastre natural al que hace referencia, Code es una columna repleta de NA's que podemos omitir, la variable Year contiene el año del conteo, y la última variable contiene la frecuencia de cada desastre natural.

```
desastres_naturales_evolución <- filter(desastres_naturales, Entity == "All natural
↳ disasters")
gráfica_evolución_desastres <- ggplot(data = desastres_naturales_evolución) +
↳ geom_line(mapping = aes(x = Year, y = Number.of.disasters..EMDAT..2020..), col =
↳ "orange2") + xlab("Años") + ylab("Número de desastres naturales");
↳ gráfica_evolución_desastres + ggtitle("Desastres Naturales")
```



La gráfica anterior ha sido elaborada con los datos del conteo de los desastres naturales desde 1900. Podemos ver que sigue una tendencia al alza como las emisiones de CO2 o la industria, sin embargo, no podemos asegurar que estas sean vinculantes. Existen dos posibles explicaciones que justifiquen la existencia de un mayor número de desastres en la actualidad que antes. La primera de ellas es que en el pasado no existían los medios de hoy en día que permiten la existencia de un mundo globalizado. Con aparatos como los móviles podemos conocer lo que ha pasado en otra parte del mundo en apenas unos segundos. Es por ello que puede que los conteos no estén completos. Pese a ello, la segunda opción es que las emisiones de CO2 y el cambio climático han afectado a la aparición de ciertos fenómenos naturales. Fenómenos como los terremotos o volcanes claramente no se verían influenciados, sin embargo, los incendios, temperaturas extremas, inundaciones, huracanes y ciclones sí podrían estar vinculados estrechamente al calentamiento global y al cambio climático. Vamos a estudiar los incendios y temperaturas extremas:

```
incendios_emisiones <- filter(desastres_naturales, Entity == "Wildfire", Year >= 1960
↳ & Year < 2019)
años <- intersect(incendios_emisiones$Year, emisiones_mundiales$Year)
```




```

emisiones_mundiales_2 <- filter(emisiones_mundiales, Year %in% años, Entity ==
↳ "World")

emisiones_incendios <- data.frame(c(incendios_emisiones$Year),
↳ c(emisiones_mundiales_2$Annual.CO2.emissions..zero.filled.),
↳ c(incendios_emisiones$Number.of.disasters..EMDAT..2020..))
colnames(emisiones_incendios) <- c("Año", "Emisiones", "Incendios")
gráfica_evolución_incendios <- ggplot(data = emisiones_incendios) +
↳ geom_point(mapping = aes(x = Incendios, y = Emisiones), col = "orange2") +
↳ xlab("Incendios") + ylab("Emisiones"); gráfica_evolución_incendios +
↳ geom_smooth(aes(x = Incendios, y = Emisiones)) + ggtitle("Relación
↳ emisiones-incendios")

```

`geom_smooth()` using method = 'loess' and formula 'y ~ x'



```

temperaturas_emisiones <- filter(desastres_naturales, Entity == "Extreme
↳ temperature", Year >= 1960 & Year < 2019)
años_2 <- intersect(temperaturas_emisiones$Year, emisiones_mundiales$Year)
emisiones_mundiales_3 <- filter(emisiones_mundiales, Year %in% años_2, Entity ==
↳ "World")

emisiones_temperaturas <- data.frame(c(temperaturas_emisiones$Year),
↳ c(emisiones_mundiales_3$Annual.CO2.emissions..zero.filled.),
↳ c(temperaturas_emisiones$Number.of.disasters..EMDAT..2020..))
colnames(emisiones_temperaturas) <- c("Año", "Emisiones", "Temperatura")


```

```

gráfica_evolución_temperaturas <- ggplot(data = emisiones_temperaturas) +
↳ geom_point(mapping = aes(x = Temperatura, y = Emisiones), col = "orange2") +
↳ xlab("Número de temperaturas extremas") + ylab("Emisiones");
↳ gráfica_evolución_temperaturas + geom_smooth(aes(x = Temperatura, y = Emisiones)) +
↳ ggtitle("Relación emisiones-temperaturas")

```

```
## `geom_smooth()` using method = 'loess' and formula 'y ~ x'
```



En ambos caso se aprecia que el modelo lineal nos da una curva creciente, sin embargo, este no se ajusta muy bien a nuestros puntos por lo distantes que son. En los años que ocurren pocos incendios, estos dependen de las emisiones siendo ambas proporcionales, sin embargo en los a medida que se registran más incendios los datos se vuelven más diversos. En cuanto a la temperatura, el modelo lineal si parece situarse mejor en nuestros puntos, por lo tanto como ya vimos anteriormente las emisiones son un factor clave en las temperaturas extremas, pese a que ocurre como en la gráfica anterior donde el modelo lineal se normalizaba.

Antes de cambiar de apartado, finalizamos el apartado sobre la población lanzándonos la hipótesis sobre si los países más afectado por los desastres naturales verían cambios en su evolución demográfica. Para este análisis necesitaremos un nuevo data frame que nos de un indicador para medir los efectos de los desastres naturales sobre países afectados:

```
muertes_desastres <- read.csv("deaths-natural-disasters-ihme.csv", header = TRUE)
```

```
head(muertes_desastres)
```

```
##      Entity Code Year
```

```
## 1 Afghanistan AFG 1990
## 2 Afghanistan AFG 1991
## 3 Afghanistan AFG 1992
## 4 Afghanistan AFG 1993
## 5 Afghanistan AFG 1994
## 6 Afghanistan AFG 1995
## Deaths...Exposure.to.forces.of.nature...Sex..Both...Age..All.Ages..Number.
## 1 0.0000
## 2 1349.9994
## 3 614.0001
## 4 110.0000
## 5 160.0000
## 6 381.0000
```


En el data frame anterior tenemos datos sobre el número de muertos por desastres naturales por país. Vamos a estudiar el caso particular de diez países. La lista de nuestros países estará compuesta por Haíti, Puerto Rico, Dominica, Honduras, Nicaragua, Myanmar, Pakistán, Bangladesh, Filipinas y Vietnam.

```
países_desastres <- c("Haiti", "Dominica", "Myanmar", "Vietnam", "Philippines",
→ "Honduras", "Nicaragua", "Puerto Rico", "Pakistan")

datos_países_afectados <- filter(muertes_desastres, Entity %in% países_desastres)


gráfica_muertes_países_afectados <- ggplot(data = datos_países_afectados) +
→ geom_line(mapping = aes(x = Year, y =
→ Deaths...Exposure.to.forces.of.nature...Sex..Both...Age..All.Ages..Number.)) +
→ xlab("Años") + ylab("Muertes") + ggtitle("Evolución muertes desastres naturales") +
→ aes(col = Entity); gráfica_muertes_países_afectados
```

Evolución muertes desastres naturales



```
gráfica_muertes_países_afectados + ylim(0, 10000)
```

Evolución muertes desastres naturales



En la gráfica anterior vemos la evolución de las muertes por fenómenos naturales según los países que mencionamos anteriormente. El más destacado es Haïti, con 300000 muertes en 2010, sin embargo, en esa año ocurrió un terremoto por lo que no cuenta como un desastre provocado por el cambio climático. Sin embargo, en Myanmar un país situado en el sureste asiático si encontramos una gran cifra de muertos cerca del 2008, año en el que el ciclón Margis devastó por completo el país dejando cerca de 140000 muertes. Este ciclón si puede considerarse como un derivado del cambio climático ya que es una alteración de los parámetros usuales de la climatología. Sin embargo, la altísima cifra de Haïti nos impide ver con claridad la evolución en otros países para progresar con nuestro análisis. Si aplicamos un límite en las 10000 muertes observamos que países Vietnam presentó cerca de los 3500 muertos en 1997 por una tormenta tropical, Haïti presento en 2004 cerca de 2500 muertos por una serie de lluvia torrenciales y huracanes, o Filipinas en 2013 donde el supertifón Haiyan se llevó la vida de cerca de 6000 personas.

Los números de los desastres naturales en estos países se han disparado en los últimos años, Haïti por ejemplo, se ha convertido en el país con menor PIB per cápita del hemisferio norte, y es que tras el terremoto del 2010 el país se ha sumergido en una cadena de desastres naturales e inestabilidades políticas que no le han permitido progresar. Siendo realistas, los países que hemos elegido no son conocidos por tener solvencia económica, vamos a ver sus emisiones de CO2 respecto a las de algunos países más relevantes económicamente como Alemania o Canadá.

```
países_análisis <- c("Haiti", "Dominica", "Myanmar", "Vietnam", "Philippines",
↳ "Honduras", "Nicaragua", "Puerto Rico", "Pakistan", "Germany", "Pakistan", "Canada")


emisines_países_des <- filter(emisiones_anuales_co2, Entity %in% países_análisis)

colnames(emisines_países_des) <- c("País", "Code", "Año", "Emisiones")

gráfica_emisiones_países_desastres <- ggplot(data = emisines_países_des) +
```

```
geom_line(mapping = aes( x = Año, y = Emisiones)) + aes(col = País) +
→ ggtitle("Evolución emisiones en países afectados") + xlab("Año") +
→ ylab("Emisiones de CO2"); gráfica_emisiones_países_desastres
```

Evolución emisiones en países afectados



Como vemos los países afectados contribuyen a las emisiones de CO2 con una cantidad ampliamente menor que países que podrían considerados ricos como Alemania o Canadá. Entonces podríamos decir que existe cierta relación entre los países afectados por desastres naturales derivados del cambio climático y su emisiones de CO2.


Vamos a fijarnos en las gráficas del Índice de Desarrollo Humano y PIB per cápita de estos países comparándolos otra vez con Alemania y Cánada:

```
datos_pib_afectados <- filter(datos_PIB, Entity %in% países_análisis)
datos_IDH_afectados <- filter(datos_IDH, Entity %in% países_análisis)

colnames(datos_pib_afectados) <- c("País", "Code", "Año", "PIB")
colnames(datos_IDH_afectados) <- c("País", "Code", "Año", "IDH")


gráfica_PIB_Afectados <- ggplot(data = datos_pib_afectados) + geom_line(mapping =
→ aes(x = Año, y = PIB)) + xlab("Año") + ylab("PIB") + ggtitle("Evolución PIB países
→ afectados") + aes(col = País); gráfica_PIB_Afectados
```

Evolución PIB países afectados



```
gráfica_IDH_afectados <- ggplot(data = datos_IDH_afectados) + geom_line(mapping =  
↳ aes(x = Año, y = IDH)) + xlab("Año") + ylab("IDH") + ggtitle("Evolución IDH países  
↳ afectados") + aes(col = País); gráfica_IDH_afectados
```

Evolución IDH países afectados



Las gráficas anteriores muestran la evolución del PIB per cápita y el Índice de Desarrollo Humano en los países afectados en mayor medida por los desastres naturales. En cuanto al PIB se refiere encontramos que gran parte de los países afectados no superan los 1000 dólares per cápita una cifra muy inferior a la de países que emiten mayor cantidad de emisiones como Canadá o Alemania. En cuanto al IDH encontramos un resultado similar con niveles inferiores al medio en la mayoría de los casos.

En cuanto su población podemos observar que:

```


datos_población_afectados <- filter(datos_población_ordenados, Country.Name %in%
↪ países_análisis)

colnames(datos_población_afectados) <- c("País", "Code", "Indicator", "Ind.code",
↪ "Año", "Población")

gráfica_ev_afectados <- ggplot(data =datos_población_afectados) + geom_line(mapping
↪ = aes( x = as.numeric(Año), y = Población)) + xlab("Años") + ylab("Población") +
↪ ggtitle("Evolución población en países afectados ") + aes(col = País);
↪ gráfica_ev_afectados

```


Evolución población en países afectados



La gráfica anterior nos muestra la evolución de la población en los distintos países afectados por desastres naturales. En este caso vemos que no existe una relación tan clara como con el IDH y el PIB, ya que Pakistán es el país con mayor población de la gráfica, superando los 200 millones, salvo este caso, los demás países no presentan una evolución demográfica normal, por lo que no podríamos determinar que los desastres naturales sean un factor clave en la población.

Conclusiones:

- Los desastres naturales han sido vinculados por diversos motivos al cambio climático. Si bien es cierto que existe un relación ascendente entre los desastres naturales y las emisiones, no podemos garantizar con veracidad esa tendencia ya que antes no existían los medios para recopilar datos que hay en la actualidad.
- Si le damos veracidad a nuestros datos, podemos ver que la ocurrencia de fenómenos relacionados con las temperaturas extremas crecen junto a las emisiones, esto nos confirma que las emisiones afectan a nuestro clima y contribuyen al llamado calentamiento global.
- En los incendios la tendencia es similar, pero las observaciones se encuentran más distantes por lo tanto no podemos garantizar una relación tan fuerte como con los fenómenos de temperaturas extremas.
- Los países más afectados por desastres naturales no generan una gran cantidad de emisiones y suelen tratarse de territorios con condiciones de vida precarias.

Transportes:

<https://ourworldindata.org/grapher/road-vehicles-per-1000-inhabitants-vs-gdp-per-capita>

El tema de los transportes nos va a permitir conocer si realmente la población puede suponer un cambio en este problema. Todos necesitamos desplazarnos en nuestra vida cotidiana, para ir a clase, para ir a trabajar. Toda acción que realicemos supone un gasto de energía, y cada desplazamiento una huella de carbono. Por ejemplo, nuestra huella de carbono se verá considerablemente reducida si optamos por viajar en guagua, bicicleta o ir caminando. Aunque los países buscan aplicar cada vez más reformas para prohibir los vehículos que emiten CO2, este es un escenario utópico y casi imposible. Los coche de gasolina o diésel poseen un precio mucho menor que los de gasolina o híbridos. Bajo este escenario vamos a tomar una medida de la Agencia Europea del medio ambiente que nos da la idea de que un coche mediano de gasolina genera 143 gramos de CO2 por kilómetro. Además vamos a tener en cuenta que en España un coche suele realizar 13000 kilómetros al año. A continuación vamos a leer un data frame sobre los vehículos a motor per cápita por país, y vamos a realizar la suposición de que se gastan tanto como un vehículo medio de gasolina(0.000143 toneladas).

```
datos_vehículos <-
↪ read.csv("road-vehicles-per-1000-inhabitants-vs-gdp-per-capita.csv", header = TRUE,
↪ sep = ",")
head(datos_vehículos)
```

```
##      Entity      Code Year
## 1  Abkhazia  OWID_ABK 2015
## 2  Afghanistan  AFG 2014
## 3  Afghanistan  AFG 2002
## 4  Afghanistan  AFG 2003
## 5  Afghanistan  AFG 2004
## 6  Afghanistan  AFG 2005
##  Motor.vehicles.per.1000.people..NationMaster..2014..
## 1                                     NA
## 2                                     28
## 3                                     NA
## 4                                     NA
## 5                                     NA
## 6                                     NA
##  GDP.per.capita..PPP..constant.2017.international...
## 1                                     NA
## 2                                2102.385
## 3                                1189.785
## 4                                1235.810
## 5                                1200.278
## 6                                1286.794
##  Population..historical.estimates. Continent
## 1                                     NA      Asia
## 2                                33370803
## 3                                22600774
## 4                                23680871
## 5                                24726689
## 6                                25654274
```

El data frame ha sido leído bajo el nombre datos_vehículos. Su estructura contiene 5 columnas, una para representar el país, otra para el año, otra para los vehículos a motor per cápita en 2014, otra que contiene el PIB per cápita, otra con la población y una última con el continente. Vamos a crear nuestra medida:

```

datos_vehículos <- filter(datos_vehículos, Year == 2014)
datos_vehículos <- datos_vehículos %>%
  mutate(Emisionesph = Motor.vehicles.per.1000.people..NationMaster..2014.. *
  → 0.000143 * Population..historical.estimates.* 13000 / 1000000)

```

Ya tenemos creada una nueva columna llamada emisionesph que contiene todas las emisiones per cápita teniendo en cuenta el número de vehículos a motor, la población, y la medidas que tomamos antes. Hemos dividido por un millón porque en el data frame de las emisiones los datos se referencian el millones de toneladas. Creemos ahora una nueva medida en el data frame de las emisiones de CO2:

```

emisiones_2014<- filter(emisiones_anuales_co2, Year == 2014)
países <- intersect(emisiones_2014$Entity, datos_vehículos$Entity)
emisiones_2014 <- filter(emisiones_2014, Entity %in% países)
datos_vehículos_2014 <- filter(datos_vehículos, Entity %in% países)

emisiones_vehículos <- data.frame(c(datos_vehículos_2014$Entity),
→ c(emisiones_2014$Annual.CO2.emissions..zero.filled.),
→ c(datos_vehículos_2014$Emisionesph))

colnames(emisiones_vehículos) <- c("País", "Emisiones", "Emisionesph")

emisiones_vehículos <- emisiones_vehículos %>%
  mutate( porcentajecoches = (Emisionesph/Emisiones)*100)

head(emisiones_vehículos)

```

```

##      País  Emisiones  Emisionesph  porcentajecoches
## 1 Afghanistan  7774340    1737.0170      0.022342952
## 2      Africa 1358705216           NA              NA
## 3     Albania   5620576     667.6451      0.011878589
## 4     Algeria 143220807     8248.9415      0.005759597
## 5     Andorra   461664           NA              NA
## 6      Angola  44248826     1903.2207      0.004301178

```

```

gráfica_ph_emisiones <- ggplot(data = emisiones_vehículos) + geom_point(mapping =
→ aes(y = Emisiones, x = porcentajecoches)) + xlab("Porcentaje emisiones coches por
→ habitantes") + ylab("Emisiones CO2") + ggtitle("Gráfica emisiones y porcentaje de
→ emisiones per cápita por movilidad"); gráfica_ph_emisiones

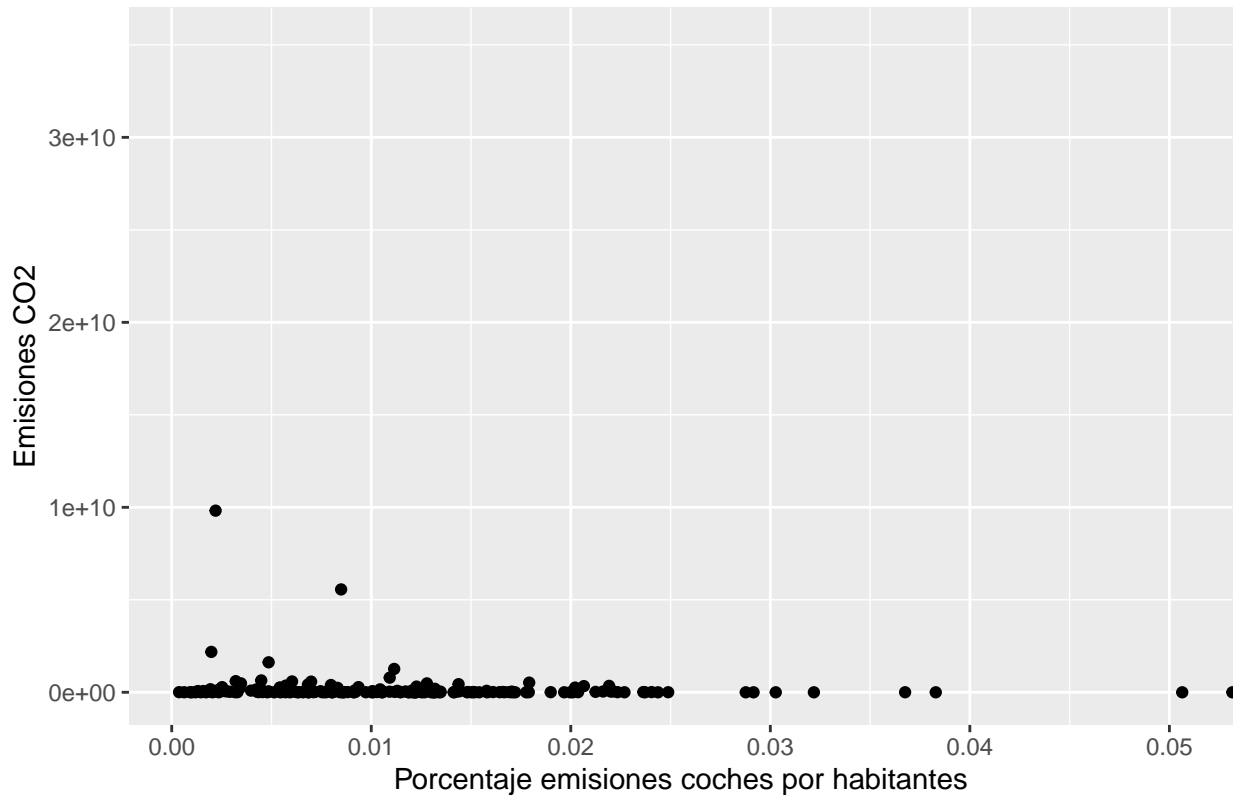
```

```

## Warning: Removed 35 rows containing missing values (geom_point).

```

Gráfica emisiones y porcentaje de emisiones per cápita por movilidad



En el code chunk anterior se crea un nuevo data frame con las medidas de emisiones, país y el porcentaje de emisiones de coche por habitante. Si nos fijamos el porcentaje es muy bajo, no superando el 1% en muchos casos. Sin embargo es un porcentaje nada despreciables ya que el 0.01 % de un millón es igual a un total de 10000 toneladas. Las gráficas pueden resultar engañosas en algunos casos como hemos visto, y este es uno de ellos.

Conclusiones:

- En comparación con todas las emisiones generadas por un país, las emisiones a nivel individual pasan a ser ridículas. Pese a ello, recordemos que un 0.01 % de un millón de toneladas equivale a 10000 toneladas al año por habitante, por lo tanto el problema si depende de nosotros.
- Todas nuestras acciones pueden ser claves para detener este problema hasta un ridículo porcentaje puede darle la pausa y tranquilidad que se merece nuestro planeta. Por ello es importante promover el transporte sostenible, y dar subvenciones o ventajas a vehículos con etiquetas medioambientales favorables.
- Las gráficas no dejan de ser más que simples representaciones de la realidad, en la mayoría de los casos son capaces de reflejarla fielmente, aunque en otro como este, no comprenden la verdadera magnitud y el transfondo que hay detrás de los datos. Las gráficas han de ser analizadas objetivamente, sin embargo, en esta es imposible no dejarse llevar por la conciencia y pensamientos para realizar un juicio correcto.

La pandemia del coronavirus, ¿punto de inflexión?:

El coronavirus ha marcado un antes y un después en nuestras vidas, siendo comparado con catástrofes como las guerras, comparación que tal vez sea un poco desmedida, porque nadie se mancho las manos de sangre salvo nuestros sanitarios. Sin embargo, bien es cierto que se nos privó de nuestra libertad con el confinamiento, tuvimos que detener nuestra vida para estar encerrados entre cuatro paredes siendo afortunados. Vamos a ver como afectó ese parón de nuestras actividades sobre las emisiones de CO2, para ello tendremos que leer una nueva tabla.

<https://ourworldindata.org/coronavirus>


```
datos_covid <- read.csv("owid-covid-data.csv", header = TRUE)
datos_covid <- datos_covid[, 1:5]
head(datos_covid)
```

```
##   iso_code continent   location      date total_cases
## 1     AFG      Asia Afghanistan 2020-02-24         5
## 2     AFG      Asia Afghanistan 2020-02-25         5
## 3     AFG      Asia Afghanistan 2020-02-26         5
## 4     AFG      Asia Afghanistan 2020-02-27         5
## 5     AFG      Asia Afghanistan 2020-02-28         5
## 6     AFG      Asia Afghanistan 2020-02-29         5
```

En el code chunk anterior hemos leído una tabla con los casos diarios de covid-19 durante 2020. Vamos a ver la tendencia de casos de España:

```
datos_covid_mundiales <- filter(datos_covid, location == "World")
gráfica_covid_mundial <- ggplot(data = datos_covid_mundiales) + geom_line(mapping=
→ aes(x = as.Date(date), y = total_cases)) + xlab("Fecha") + ylab("Casos acumulados") +
→ ggtitle("Casos covid en el mundo desde el inicio de la pandemia");
→ gráfica_covid_mundial
```

Casos covid en el mundo desde el inicio de la pandemia



En la gráfica anterior podemos ir siguiendo los casos de covid conocidos según la fecha. Vemos que estos siguen una tendencia ascendente, algo obvio teniendo en cuenta que hablamos de casos acumulados. Los casos han llegado a superar rápidamente los 100 millones en un período de un año. No he sido capaz de encontrar ningún dato sobre las emisiones de CO2 a lo largo de este año ni de 2020, pese a ello hay otros factores que pueden ayudarnos a descubrir

<https://www.imf.org/en/Publications/WEO/weo-database/2021/October>

```
datos_pib_covid <- read.csv("WEO_Data2020-2022.xls.csv", header = TRUE, sep = ";")
head(datos_pib_covid)
```

```
##           Country           Subject.Descriptor           Units
## 1  Afghanistan Gross domestic product, current prices U.S. dollars
## 2    Albania Gross domestic product, current prices U.S. dollars
## 3    Algeria Gross domestic product, current prices U.S. dollars
## 4   Andorra Gross domestic product, current prices U.S. dollars
## 5    Angola Gross domestic product, current prices U.S. dollars
## 6 Antigua and Barbuda Gross domestic product, current prices U.S. dollars
##      Scale
## 1 Billions
## 2 Billions
## 3 Billions
## 4 Billions
## 5 Billions
## 6 Billions
##
##                               Country.Series.specific.Notes
```

```
## 1 See notes for: Gross domestic product, current prices (National currency).
## 2 See notes for: Gross domestic product, current prices (National currency).
## 3 See notes for: Gross domestic product, current prices (National currency).
## 4 See notes for: Gross domestic product, current prices (National currency).
## 5 See notes for: Gross domestic product, current prices (National currency).
## 6 See notes for: Gross domestic product, current prices (National currency).
##      X2019  X2020   X2021  X2022 Estimates.Start.After
## 1  18.876  20.136    n/a    n/a                2019
## 2  15.283  14.828  16.770  18.012                2020
## 3 171.070 147.600 163.812 168.195                2019
## 4   3.155   2.858   3.213   3.460                2020
## 5  84.516  58.376  70.339  74.953                2020
## 6   1.687   1.370   1.405   1.534                2019
```

En el code chunk anterior leemos un data frame que proviene del explorador de datos del IMF. Sus columnas están compuestas por país, descripción de la medida(en este caso PIB en billones de dólares), y las columnas con los años de las medidas. Este data frame esta desordenado por lo que vamos a arreglarlo:

```
datos_pib_covid_tidy <- as_tibble(datos_pib_covid)
datos_pib_covid_tidy <- datos_pib_covid_tidy %>% select(1, 6, 7, 8, 9)
names(datos_pib_covid_tidy) <- sub("^X", "", names(datos_pib_covid_tidy))
datos_pib_covid_tidy <- gather(datos_pib_covid_tidy, "Año", "PIB",-1)
```

En el code chunk anterior hemos convertido en tidy el data frame del Producto Interior Bruto. En este caso hemos sustituido las x que aparecen en los nombre del columnas con los años para poder pasar esos valores como componentes de una nueva columna llamada año, los valores del PIB pasan a la columna con el mismo nombre. Vamos a comprobar la evolución del PIB con ggplot, porque ya conocemos que existe un vínculo entre emisiones y economía, entonces esta última nos puede servir como indicador de las emisiones pese a no conocerlas.

```
datos_pib_españa <- filter(datos_pib_covid_tidy, Country == "Spain")
años_pib_covid <- as.numeric(datos_pib_españa$Año)


PIB_españa <- c(1393.200, 1280.459, 1439.958, 1570.910)

datos_pib_covid_gráfica <- data.frame(c(años_pib_covid), c(PIB_españa))

colnames(datos_pib_covid_gráfica) <- c("Año", "PIB")

gráfico_pib_mundial <- ggplot(datos_pib_covid_gráfica) + geom_line(mapping = aes( x=
↪ Año, y = PIB), col = "blue") + xlab("Año") + ylab("PIB") + ggtitle("Evolución PIB por
↪ años"); gráfico_pib_mundial
```

Evolución PIB por años



Como vemos nuestra gráfica presenta un punto de inflexión y un mínimo en 2020, causado por el detenimiento de las actividades económicas y el parón de la sociedad. El IFM realiza una aproximación a años siguientes indicando que crecerá hasta valores superiores a los de 2019. Puede que el covid haya dado un pequeño bajón a las emisiones (recordemos que entre mayor economía más emisiones), sin embargo, esos valores se recuperarán en cuanto se eliminen las políticas de confinamiento, dejándonos con el mismo problema de antes.

Resumen de conclusiones:

- La historia de un país puede ser comprendida por sus emisiones de dióxido de carbono. Los índices de este compuesto aumentaron cuando los países se introdujeron en su etapa industrial. Además, los períodos de guerra han supuesto puntos de inflexión en ese crecimiento, sin embargo, tras estos los niveles de CO₂ se recuperaban, produciendo un incremento exponencial desde entonces hasta ahora. Esto ha causado que algunos países a partir de la década del 2000 hayan tomado conciencia de la situación tomando medidas como el tratado de París (2015).
- Las son periodos donde se disminuyen las emisiones de CO₂, pese a ello no solo son nefastas para la humanidad, si no que también afectan al medio ambiente con pruebas nucleares que pueden causar áreas contaminadas.
- Las emisiones de CO₂ están estrechamente vinculados con la temperatura, a mayor crecimiento de la temperatura mayores emisiones. La temperatura ha fomentado el calentamiento global con la pérdida de hielo en polos, y por consiguiente la subida del nivel del mar. Esto podría producir una gran crisis migratoria con la pérdida de hogares.
- Las muertes por contaminación del aire son una causa directa de las emisiones de CO₂. Antes esas muertes eran mucho menos comunes que en la actualidad, lo que indica la relación con las emisiones.

- Acumular riqueza ha sido uno de los objetivos de la humanidad a lo largo de los años. Sin embargo, la riqueza en la mayoría de ocasiones se relaciona con el materialismo y el consumismo. Los países más ricos suelen tener mayores producciones industriales y con ello más emisiones.
- La demografía de un país afecta a su contribución con CO2 al efecto invernadero. En el conjunto los países con más habitantes poseen mayores emisiones. Sin embargo a nivel individual los habitantes de los países suele producir cantidades similares de CO2.
- Los desastres naturales son hechos aislados y desafortunados que se han comenzado a dar con mayor frecuencia en los últimos años. Desastres naturales como los incendios y las temperaturas extremas se encuentran relacionados con con el calentamiento global. Otra perspectiva para abarcar esta tendencia creciente es que antes no existían tantos instrumentos de medición como ahora lo que dificultaba su conteo. Los países que más catastrofes naturales sufren suelen ser países desfavorecidos que además no contribuyen en gran medida a las emisiones de CO2.
- El hecho de que las emisiones se encuentren relacionadas con la industria puede distraernos y convencernos de que la culpa de la contaminación reside en las grandes empresas. Sin embargo, en nuestro día a día usamos vehículos para desplazarnos, vehículos que desprenden CO2. Pese a que nuestras emisiones son ridículas respecto a las que genera la totalidad de un país, estas siguen siendo importantes. Deberíamos impulsar una sociedad en la que todos contribuyamos en la menor medida posible al cambio climático y uno de sus pasos es el transporte sostenible por que podemos optar a diario.
- El coronavirus llegó a nuestras vidas para cambiarlas, durante el confinamiento vimos países enteramente detenidos. Esa pausa que ha optado por tomar la naturaleza, ha reducido la economía y conjuntamente las emisiones. Sin embargo, ese confinamiento poblacional ya ha finalizado, y ahora nos encontramos retornando a la normalidad y a las emisiones.

App shiny:

```

library(shiny)
library(shinythemes)
library(dplyr)
library(readr)
library(shinyWidgets)
library(leaflet)
library(rsconnect)

ui <- fluidPage(theme = shinytheme("superhero"),
  titlePanel("Gráficas Interactivas"),
  sidebarLayout(
    sidebarPanel(
      titlePanel("Gráfica CO2"),
      selectInput(inputId = "país",
        label = strong("Selecciona el país:"),
        choices = unique(emisiones_anuales_co2$Entity),
        selected = "World"),
      numericRangeInput("Year",
        strong("Año"),
        min = 1750,
        max = 2020,
        value= c(1750, 2020)),
      checkboxInput(inputId = "lm", label = strong("Aplicar modelo lineal")),
      conditionalPanel(condition = "input.lm == true",

```

```

sliderInput(inputId = "f",
            label = "Smoother span:",
            min = 0.01, max = 1,
            value = 0.67, step = 0.01,
            animate = animationOptions(interval = 100)),
            HTML("Los valores menores son más precisos"))
    ),

    mainPanel(
      plotOutput(outputId = "lineaplot", height = "300px"),
      textOutput(outputId = "desc"),
      tags$a(href = "https://ourworldindata.org/co2-emissions", "Source: Our World in data CO2 emissions", target =
"_blank")
    )
  ),

  sidebarLayout(
    sidebarPanel(
      titlePanel("Gráfica PIB"),
      selectInput(inputId = "PIB",
                  label = strong("Selecciona el país:"),
                  choices = unique(datos_PIB$Entity),
                  selected = "World"),
      numericRangeInput("YearPIB",
                         strong("Año"),
                         min = 1950,
                         max = 2020,
                         value = c(1950, 2020)),
      checkboxInput(inputId = "lmPIB", label = strong("Aplicar modelo lineal")),
      conditionalPanel(condition = "input.lmPIB == true",
                       sliderInput(inputId = "t",
                                    label = "Smoother span:",
                                    min = 0.01, max = 1,
                                    value = 0.67, step = 0.01,
                                    animate = animationOptions(interval = 100)),
                       HTML("Los valores menores son más precisos"))
    ),
    mainPanel(
      plotOutput(outputId = "lineaplotPIB", height = "300px"),
      textOutput(outputId = "descPIB"),
      tags$a(href = "https://ourworldindata.org/economic-growth", "Source: Our World in data GDP per cápita", target =
"_blank")
    )
  ),

  sidebarLayout(
    sidebarPanel(
      titlePanel("Mapa radioactividad"),
      selectInput(inputId = "radio",
                  label = strong("Medida muestra"),
                  choices = "Radioactividad")
    ),
    mainPanel(
      leafletOutput("mapa", height = "300px"),
      textOutput(outputId = "descMapa"),
      tags$a(href = "https://interestingengineering.com/12-of-the-most-radioactive-places-on-earth", "Source:
Interestingengineering", target = "_blank")
    )
  ),

```

```

sidebarLayout(
  sidebarPanel(
    titlePanel("Gráfica IDH"),
    selectInput(inputId = "IDH",
      label = strong("Selecciona el país"),
      choices = unique(datos_IDH$Entity),
      selected = "Spain"),
    numericRangeInput("YearIDH",
      strong("Año"),
      min = 1995,
      max = 2017,
      value= c(1995, 2017)),
    checkboxInput(inputId = "lmIDH", label = strong("Aplicar modelo lineal")),
    conditionalPanel(condition = "input.lmIDH == true",
      sliderInput(inputId = "c",
        label = "Smoother span:",
        min = 0.01, max = 1,
        value = 0.67, step =0.01,
        animate = animationOptions(interval = 100)),
      HTML("Los valores menores son más precisos"))
  ),
  mainPanel( plotOutput(outputId = "lineaplotIDH", height = "300px"),
    textOutput(outputId = "descIDH"),
    tags$a(href = "https://ourworldindata.org/human-development-index", "Source: Our World in data IDH by Max
Roser", target = "_blank"))
)
)

server <- function(input, output) {
  país_seleccionado <- reactive({
    req(input$Year)
    validate(need(!is.na(input$Year[1]) & !is.na(input$Year[2]), "Error: Introduce valores adecuados."))
    validate(need(input$Year[1] < input$Year[2], "Error: Debes introducir como primer parámetro un año menor que el
segundo"))
    emisiones_anuales_co2 %>%
    filter(
      Entity == input$país,
      Year > input$Year[1] & Year < input$Year[2]
    )
  })
  output$lineaplot <- renderPlot({
    color = "#FF1717"
    par(mar = c(4, 4, 1, 1))
    plot(x = país_seleccionado()$Year, y = país_seleccionado()$Annual.CO2.emissions..zero.filled., type = "p", xlab = "Año",
      ylab = "Emisiones de CO2", col = "brown", fg = color, col.lab = "#000000")
    if(input$lm){
      smooth_curve <- lowess( y = país_seleccionado()$Annual.CO2.emissions..zero.filled., x = país_seleccionado()$Year,
f = input$f)
      lines(smooth_curve, col = "#3138CB", lwd = 3)
    }
  })
  output$desc <- renderText({
    paste("La gráfica muestra las emisiones de CO2 basadas en la quema de combustible fósiles de", input$país, "entre", input
$Year[1], "y", input$Year[2])
  })

  país_seleccionado_PIB <- reactive({
    req(input$YearPIB)
    validate(need(!is.na(input$YearPIB[1]) & !is.na(input$YearPIB[2]), "Error: Introduce valores adecuados."))
  })
}

```

```

validate(need(input$YearPIB[1] < input$YearPIB[2], "Error: Debes introducir como primer parámetro un año menor que el
segundo"))
  datos_PIB %>%
  filter(
    Entity == input$PIB,
    Year > input$YearPIB[1] & Year < input$YearPIB[2]
  )
})
output$lineaplotPIB <- renderPlot({
  color = "#FF1717"
  par(mar = c(4, 4, 1, 1))
  plot(x = país_seleccionado_PIB()$Year, y = país_seleccionado_PIB()$GDP.per.capita, type = "p", xlab = "Año", ylab =
"PIB per cápita", col = "brown", fg = color, col.lab = "#000000")
  if(input$lmPIB){
    smooth_curve_PIB <- lowess( y = país_seleccionado_PIB()$GDP.per.capita, x = país_seleccionado_PIB()$Year, f =
input$t)
    lines(smooth_curve_PIB, col = "#3138CB", lwd = 3)
  }
})
output$descPIB <- renderText({
  paste("La gráfica muestra el PIB per cápita en", input$PIB, "entre", input$YearPIB[1], "y", input$YearPIB[2])
})

output$mapa <- renderLeaflet({
  leaflet() %>% addTiles() %>% addMarkers(data = datos_radioactividad, lat = ~Lat, lng = ~Long, popup = ~popup_info )
})

output$descMapa <- renderText({
  paste("El mapa muestra los lugares con mayores niveles de radioactividad del mundo, indicado su ubicación y causa.")
})
país_seleccionadoIDH <- reactive({
  req(input$YearIDH)
  validate(need(!is.na(input$YearIDH[1]) & !is.na(input$YearIDH[2]), "Error: Introduce valores adecuados.))
  validate(need(input$YearIDH[1] < input$YearIDH[2], "Error: Debes introducir como primer parámetro un año menor
que el segundo"))
  datos_IDH %>%
  filter(
    Entity == input$IDH,
    Year > input$YearIDH[1] & Year < input$YearIDH[2]
  )
})
output$lineaplotIDH <- renderPlot({
  color = "#FF1713"
  par(mar = c(4, 4, 1, 1))
  plot(x = país_seleccionadoIDH()$Year, y = país_seleccionadoIDH()$Human.Development.Index..UNDP., type = "p",
xlab = "Año", ylab = "IDH", col = "brown", fg = color, col.lab = "#000000")
  if(input$lmIDH){
    smooth_curve <- lowess( y = país_seleccionadoIDH()$Human.Development.Index..UNDP., x =
país_seleccionadoIDH()$Year, f = input$c)
    lines(smooth_curve, col = "#3138CB", lwd = 3)
  }
})
output$descIDH <- renderText({
  paste("La gráfica muestra la evolución del Índice de Desarrollo Humano en", input$IDH, "entre", input$YearIDH[1], "y",
input$YearIDH[2])
})
}

shinyApp(ui = ui, server = server)

```

El código anterior crea una web interactiva usando la librería shiny, que proporciona un entorno basado en la conexión ui con servidor. Hemos usado los datos de las emisiones anuales de CO2, los del Producto Interior Bruto, los del Índice de desarrollo humano, y hemos añadido el mapa que no se podía ver en rmarkdown. La web se divide en las tres gráficas y el mapa. La interactividad del mapa viene en que puedes desplazarte por él, y conocer información sobre los puntos registrados. Mientras, las otras tres gráficas tienen una estructura similar. Tienes que seleccionar primero la región que quieres ver representada en el panel de la derecha, tras ello puedes seleccionar el intervalo de años a través de flechas. Por último existe una opción de aplicar un modelo lineal con su propio coeficiente, siguiendo el método de loess. Con cada gráfica o mapa se incluye una pequeña descripción que nos lleva a las páginas donde se han sacado los datos, a la vez que muestra sobre que años y país estamos viendo la gráfica. Al principio de esta memoria se adjunta un vídeo donde se muestra la ejecución del código anterior.

Fuentes data frames:

- Datos emisiones CO2: Hannah Ritchie and Max Roser (2020) - “CO2 and Greenhouse Gas Emissions”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/co2-and-other-greenhouse-gas-emissions> [Online Resource]
- Datos Nivel del mar:

Hannah Ritchie and Max Roser (2020) - “CO2 and Greenhouse Gas Emissions”. https://ourworldindata.org/explorers/climate-change?facet=none&country=~OWID_WRL&Metric=Sea+level+rise&Long-run+series%3F=false Published online at OurWorldInData.org. Retrieved from: [Online Resource]

- Datos sectores económicos:

Our World in Data (Nicolas Lippolis) based on Berthold Herrendorf, Richard Rogerson and Akos Valentinyi (2014) – “Growth and Structural Transformation” Handbook of Economic Growth Vol.2B <https://ourworldindata.org/grapher/shares-of-gdp-by-economic-sector?country=~SWE>

- Datos muertes por contaminación aire:

Data Review: How many people die from air pollution? by Max Roser from: <https://ourworldindata.org/data-review-air-pollution-deaths>

- Datos PIB:

Max Roser (2013) - “Economic Growth”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/economic-growth> [Online Resource]

- Datos IDH:

Max Roser (2014) - “Human Development Index (HDI)”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/human-development-index> [Online Resource]

- Datos_temperatura:

Hannah Ritchie and Max Roser (2020) - “CO2 and Greenhouse Gas Emissions”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/co2-and-other-greenhouse-gas-emissions> [Online Resource]

- Datos glaciares:

<https://ourworldindata.org/grapher/mass-balance-us-glaciers?country=Gulkana+Glacier~Lemon+Creek+Glacier~South+Cascade+Glacier~Wolverine+Glacier> Fuente_ OurWorldinData Source: United States Environmental Protection Agency (EPA) <https://www.epa.gov/climate-indicators/climate-change-indicators-glaciers>

- Datos población:

<https://data.worldbank.org/indicador/SP.POP.TOTL> Fuente: Data World Bank

- Datos muertes desastres naturales:

Hannah Ritchie and Max Roser (2014) - “Natural Disasters”. Published online at OurWorldInData.org. Retrieved from: <https://ourworldindata.org/natural-disasters> [Online Resource]

- Datos desastres naturales: <https://ourworldindata.org/grapher/number-of-deaths-from-natural-disasters> Hannah Ritchie and Max Roser (2014) - “Natural Disasters”. Published online at OurWorldInData.org. Retrieved from: ‘<https://ourworldindata.org/natural-disasters>’ [Online Resource]
- Datos PIB con previsiones para cubrir el tema del coronavirus:

<https://www.imf.org/en/Publications/WEO/weo-database/2021/October> Fuente: IMF Database.

- Datos covid:

Hannah Ritchie, Edouard Mathieu, Lucas Rodés-Guirao, Cameron Appel, Charlie Giattino, Esteban Ortiz-Ospina, Joe Hasell, Bobbie Macdonald, Diana Beltekian and Max Roser (2020) - “Coronavirus Pandemic (COVID-19)”. Published online at OurWorldInData.org. Retrieved from: ‘<https://ourworldindata.org/coronavirus>’ [Online Resource] <https://ourworldindata.org/coronavirus>

- Datos puntos elevación media:

https://en.wikipedia.org/wiki/List_of_countries_by_average_elevation Fuente: Wikipedia

Fuentes de información:

- Gases efecto invernadero: <https://www.fundacionaquae.org/los-gases-de-efecto-invernadero/> Fuente: Fundación aquae
- Cambio climático:

<http://www.ideam.gov.co/web/atencion-y-participacion-ciudadana/cambio-climatico> Fuente: www.ideam.gov.co

- Calentamiento global:

<https://www.nationalgeographic.es/medio-ambiente/que-es-el-calentamiento-global> Fuente: National Geographic

- Milagro económico español:

https://es.wikipedia.org/wiki/Milagro_econ%C3%B3mico_espa%C3%B1ol Fuente: Wikipedia

- Acuerdo de París:

<https://unfccc.int/es/process-and-meetings/the-paris-agreement/el-acuerdo-de-paris> Fuente: United Nations Climate Change

- Madrid Central:

<https://elpais.com/espana/madrid/2021-09-14/guia-util-para-circular-por-el-nuevo-madrid-central-que-cambia-que-pasa-con-las-nuevas-multas.html> Fuente: El País

- Información sobre China: <https://www.youtube.com/watch?v=yKQHeHGlaUE> Fuente: Youtube, Canal: RT en español
- Atolón Enetewak:

<https://www.bbc.com/mundo/noticias-internacional-48319829> Fuente: BBC https://en.wikipedia.org/wiki/Enwetak_Atoll Fuente: Wikipedia

- Lugares más radioactivos:

<https://interestingengineering.com/12-of-the-most-radioactive-places-on-earth> Fuente: interestingengineering.com

- Países cambio climático:

<https://www.elagoradiario.com/agorapedia/10-paises-mas-afectados-cambio-climatico/> Fuente: elagoradiario.com