

# Análisis de polarización en redes sociales sobre temas afines al cambio climático

Federico Moss



Tesis de Licenciatura en Ciencias Físicas  
Facultad de Ciencias Exactas y Naturales  
Universidad de Buenos Aires

Mayo 2023



**Tema:** Análisis de polarización en redes sociales sobre temas afines al cambio climático

**Alumno:** Federico Moss

**L.U. N°:** 519-16

**Lugar de Trabajo:** Instituto de Física de Buenos Aires

**Director del Trabajo:** Pablo Balenzuela

**Colaborador del Trabajo:** Sebastián Pinto

**Fecha de Iniciación:** Marzo 2022

**Fecha de Finalización:** Mayo 2023

**Fecha del Examen Final:**

Informe Final Aprobado por:

---

Autor

---

Jurado

---

Director

---

Jurado

---

Profesor de Tesis de Licenciatura

---

Jurado



## Resumen

En esta tesis estudiamos la emergencia de polarización en debates relacionados con el cambio climático en Twitter. Para esto, implementamos un modelo que permite cuantificar el grado de polarización de una discusión en función de las interacciones entre usuarios y un grupo de influencers. Este modelo, que se conoce como “Latent Ideology”, condensa la información de la red de interacciones entre usuarios e influencers en un espacio de dimensión inferior, el “Espacio Latente”. Específicamente, trabajaremos condensando información de interacciones en redes de retweets a un espacio unidimensional. Cada elemento de este espacio unidimensional es un “score” asociado a cada usuario involucrado. Usuarios con score similar comparten interacciones con un grupo común de influencers (y por lo tanto podemos decir que tienen una ideología similar) y usuarios con scores opuestos no comparten interacciones con el mismo grupo de influencers.

En particular, nuestro objeto de estudio son las discusiones sociales en relación con las conferencias anuales sobre el cambio climático, las Conference of the Parties o, simplemente, COP. En concreto, trabajaremos con dos conferencias en particular, la COP21 (2015) y la COP26 (2020) pues son las más relevantes de los últimos años [1].

Dentro del debate en Twitter en torno a estas conferencias, pudimos aislar un debate ambientalista a partir del filtrado de usuarios específicos y la aplicación iterativa del modelo. En la distribución de scores de los usuarios de la discusión ambientalista observamos 2 subgrupos de usuarios bien definidos. Tras el análisis de los tweets asociados a cada subgrupo, identificamos un subgrupo mayoritario con una postura más tradicional respecto al cambio climático y un subgrupo conformado por menos cantidad de usuarios con una postura más crítica hacia las políticas ambientalistas para hacer frente a los problemas climáticos.

También, analizando las redes de retweets, identificamos la formación de cámaras de eco en la discusión en términos del score de Latent Ideology: usuarios que pertenecen a uno de los subgrupos mencionados tienden a interactuar principalmente con usuarios que pertenecen al mismo subgrupo. Por último, estudiamos la posible existencia de una correlación entre el score de los usuarios y la filiación política de cada uno a partir de la presencia de políticos identificados en los grupos de influencers mayoritarios y minoritarios. Dicha correlación no fue encontrada en el dataset analizado.



# Índice general

<b>1. Introducción</b>	<b>1</b>
<b>2. Datos</b>	<b>3</b>
2.1. Filtrado . . . . .	4
2.2. Base de datos de políticos . . . . .	5
<b>3. Métodos</b>	<b>6</b>
3.1. Latent Ideology . . . . .	6
3.1.1. Evolución histórica . . . . .	6
3.1.2. Correspondence analysis (CA) . . . . .	7
3.1.3. Parámetros del modelo . . . . .	10
3.1.4. Full SVD y Randomized SVD . . . . .	11
3.1.5. Ejemplo de aplicación . . . . .	12
3.2. Dip Test de Hartigan . . . . .	15
3.3. Análisis de tópicos con BERT . . . . .	17
3.4. Construcción y análisis de redes de retweets . . . . .	18
3.4.1. Detección de comunas en la red . . . . .	18
3.4.2. Homofilia de la red . . . . .	19
<b>4. Resultados</b>	<b>21</b>
4.1. Propiedades generales del dataset . . . . .	21
4.2. Polarización con Latent Ideology . . . . .	23
4.2.1. Caracterización de la discusión . . . . .	23
4.2.2. Caracterización de los polos . . . . .	26
4.3. Redes de retweets . . . . .	30
4.3.1. Cámaras de Eco . . . . .	30
4.3.2. Redes de retweets de influencers . . . . .	31
4.3.3. Detección de comunas . . . . .	33
4.4. Dimensión Política . . . . .	35

<b>5. Conclusiones</b>	<b>39</b>
<b>6. Apéndice</b>	<b>42</b>
6.1. Barrido en parámetros del modelo . . . . .	42
6.1.1. Variación de $m$ . . . . .	42
6.1.2. Variación de $n$ . . . . .	45
6.1.3. Variación de $k$ . . . . .	46
6.2. Filtrado de usuarios . . . . .	48
6.2.1. Filtrado iterativo de usuarios de la COP21 . . . . .	48
6.2.2. Filtrado iterativo de usuarios de la COP26 . . . . .	52
6.3. Robustez del método: Definición de influencer . . . . .	60
6.4. Contribución en Python . . . . .	61
6.4.1. Funciones principales del paquete . . . . .	61



# 1. Introducción

A pesar de que el 97% de los científicos que trabajan en temas afines al cambio climático ha concluido que el calentamiento global causado por el ser humano está efectivamente ocurriendo [2, 3], en una encuesta del Public Policy Polling en el año 2013 se obtuvo que más del 37% de los estadounidenses creen que el calentamiento global es un “engaño” [4].

La existencia de una brecha tan amplia entre el consenso científico y la opinión pública en un tema tan crucial como el cambio climático genera preocupación y resalta la importancia de estudiar la polarización existente en torno este tema [2]. Es esencial comprender los factores que contribuyen a esta brecha para abordar los desafíos planteados por el cambio climático de manera efectiva. La comprensión de los elementos que generan polarización y la forma en que se difunden las ideas en las redes sociales puede brindar a los responsables de la toma de decisiones la oportunidad de diseñar estrategias más efectivas (y respaldadas por evidencias) para la comunicación de las políticas necesarias para enfrentar al cambio climático [5].

En este trabajo abordaremos el tema de polarización en temas relacionados con el cambio climático mediante un estudio en la red social Twitter centrándonos específicamente en el contexto de los debates en torno a las Conference of the Parties (COP). Las COP son las conferencias anuales que se llevan a cabo desde 1995 como parte de la Convención Marco de las Naciones Unidas sobre el Cambio Climático (UNFCCC). Durante estas conferencias, los países miembros, junto con organizaciones no gubernamentales y otros actores relevantes, se reúnen para discutir y negociar medidas relacionadas con el cambio climático. El objetivo principal de las COP es coordinar esfuerzos a nivel global para abordar el calentamiento global y encontrar soluciones efectivas para mitigar sus impactos [6].

Hay tres razones fundamentales por las cuales enfocamos el estudio en las COP [1]. En primer lugar, cada COP es un evento discreto que se repite anualmente, lo que permite un análisis cuantitativo y a largo plazo de polarización en este contexto. En segundo lugar, al centrarnos en un evento específico, nos aseguramos de que el contenido de los tweets esté enfocado temáticamente: en este caso, en políti-

---

cas climáticas. Por último, la COP es el principal foro internacional de diplomacia climática y atrae una considerable atención pública [7, 8]. Por lo tanto, la COP representa un evento ideal para estudiar polarización con perspectivas climáticas.

Siguiendo el enfoque de [1], vamos a estudiar 2 conferencias en particular: la COP del año 2015 y la COP del año 2021. Dado que la COP1 representa la primera Conference of the Parties, la COP2 representa la segunda, y así sucesivamente, las conferencias de los años 2015 y 2021 corresponden a las conferencias COP21 y COP26 (la COP26 se vio retrasada 1 año por la pandemia del COVID19).

Las conferencias COP21 y COP26 son de particular importancia pues en la COP21 se firmó el Acuerdo de París y en la COP26 se acordó el Pacto de Glasgow. El Acuerdo de París es un tratado internacional que busca mantener el aumento de la temperatura global promedio por debajo de los 1.5°C por encima de los niveles pre-industriales. Para ello, propone una serie de medidas económicas en donde los países desarrollados deben brindar apoyo financiero y tecnológico a los países en desarrollo para ayudarles a reducir sus emisiones de gases de efecto invernadero [9]. Por otro lado, el pacto de Glasgow es un tratado un tanto menos ambicioso que el acuerdo de París en donde se propone nuevamente limitar el aumento de temperatura global promedio por debajo de los 1.5°C y se imponen medidas económicas más rigurosas.

Dado que estas conferencias tuvieron una notable popularidad en las redes, la creación de contenido y la participación en el debate fueron mas amplios que en las conferencias intermedias [1]. Por esta razón es que estudiaremos polarización en estas 2 conferencias en particular.

Como mencionamos, basamos nuestro trabajo en el estudio de debates en Twitter pues, según [10] y [11], es una red ampliamente utilizada por políticos y periodistas, y tiene una amplia influencia social y cultural. Esto hace que Twitter sea la plataforma ideal para realizar estudios de polarización social. Existen diferentes enfoques para estudiar la polarización en redes sociales. Entre ellos se encuentran el análisis de contenido, en donde se utilizan técnicas de procesamiento de lenguaje natural y minería de texto para extraer información relevante [12]; el análisis de sentimiento, en donde se utilizan algoritmos para clasificar los mensajes en función de su “carga emocional” [13]; y el análisis de la estructura de las interacciones entre los usuarios.

En nuestro estudio, emplearemos un enfoque que se basa en el análisis de la estructura de las interacciones entre los usuarios de la red. Específicamente, utilizaremos un modelo que busca detectar patrones de interacción entre usuarios para identificar subgrupos ideológicamente similares. Este método, que busca representar la “ideología de los usuarios” en un espacio unidimensional, se conoce como “Latent Ideology” y se describe detalladamente en la sección 3.1.

## 2. Datos

Se obtuvo una base de datos a partir de interacciones entre usuarios de la plataforma “Twitter”. En Twitter, un usuario puede escribir una opinión mediante un post (escribir un tweet), compartir posts de otros usuarios (retweets), compartir posts de otros usuarios y escribir al respecto (quote), y comentar en los tweets de los usuarios. Los usuarios pueden “seguir” a otros usuarios mediante un “follow”, tienen asociados un nombre dentro de la plataforma (username) y la cuenta asociada a un usuario puede ser “verificada” por Twitter si ese usuario está asociado a una cuenta activa, relevante y auténtica de interés público [14].

Mediante la API brindada por la plataforma se puede obtener toda la información (tweets, retweets, quotes, comentarios) que involucró el uso de una palabra específica (keyword) durante un periodo temporal determinado, como así también tener acceso a la información de los usuarios involucrados que se encuentra disponible en el campo donde cada usuario se describe a sí mismo (bio).

En este trabajo, obtuvimos los datos de tweets, retweets, quotes, comentarios y la metadata de los usuarios involucrados a partir de la búsqueda de las keywords “COP21” y “COP26”. Los periodos de recolección de datos corresponden a 6 meses antes y 6 meses después del comienzo de las conferencias. La cantidad de datos y el período específico estudiado para cada COP se muestran en la tabla 2.1. Cabe destacar que, para ser consistentes con el paper de referencia utilizado para este trabajo [1], el periodo de análisis de datos para la COP26 va desde el 1/6/2021 hasta el 14/11/2021.

COP	Fecha de la conferencia	Periodo de recolección de datos	Tweets originales	Usuarios
COP 21	30/11/2015 al 12/12/2015	01/06/2015 al 31/05/2016	$1,5 \times 10^6$	$2,9 \times 10^6$
COP 26	31/10/2021 al 12/11/2021	01/06/2021 al 31/05/2022	$4,4 \times 10^6$	$7,9 \times 10^6$

**Tabla 2.1:** Resumen de las estadísticas para cada Conference of the Parties.

Los datos obtenidos los organizamos en 2 datasets. Por un lado, tenemos el dataset de los tweets (tweets originales, retweets, quotes y comentarios) y por otro tenemos la metadata de los usuarios. En el dataset de tweets tenemos información

de cuándo fue creado el tweet, el texto del tweet, un número de identificación (ID) único asociado, el ID del autor del tweet y el ID del autor del tweet original en el caso de que se trate de un retweet o quote. En la metadata de los usuarios tenemos información respecto a la cantidad de seguidores y la cantidad de usuarios seguidos por el usuario, la ubicación geográfica que identifica al usuario, la cantidad de tweets originales del usuario, si se trata de un usuario verificado, el username que identifica al usuario y un ID único para cada cuenta.

## 2.1. Filtrado

Una parte importante del trabajo consistió en el filtrado (curado) de los tweets y los usuarios. El filtrado permite centrar el análisis en el tema específico que se desea investigar. A su vez, impone un control de calidad de los datos pues ayuda a eliminar información irrelevante, lo que a su vez contribuye a obtener resultados más confiables y precisos. Además, reducir el volumen de información a analizar permite enfocarse en la información más significativa, lo que facilita el proceso de análisis.

En primera instancia, por simplicidad idiomática para el análisis del lenguaje de los tweets, consideramos solo posts en inglés. Luego, para limitar las posibles cuentas automatizadas (bots), siguiendo el enfoque en el tratamiento de los datos implementado en el paper de Baronchelli et. al. [1], consideraremos solo tweets originales escritos mediante dispositivos móviles (IOS y Android). Por último, no consideramos usuarios con cuentas no activas (baneadas) o usuarios eliminados al momento del análisis de los datos. La tabla 2.2 muestra algunas estadísticas del filtrado.

COP	Tweets originales	Usuarios involucrados	Tweets originales tras filtrado	Usuarios involucrados tras filtrado
COP 21	$1,5 \times 10^6$	$2,9 \times 10^6$	$1,8 \times 10^5$	$2,5 \times 10^5$
COP 26	$4,4 \times 10^6$	$7,9 \times 10^6$	$3,4 \times 10^5$	$6,4 \times 10^5$

**Tabla 2.2:** Estadísticas relacionadas al filtrado para cada Conference of the Parties.

Es importante destacar que el método que estudiaremos en esta tesis (Latent Ideology) impone un conjunto de restricciones de filtrado más rigurosas. Por empezar, existen usuarios que no serán tenidos en cuenta por no haber interactuado con un conjunto de otros usuarios en particular. Esto se detalla más adelante, en la sección 3.1.3. Por otro lado, también se filtran usuarios seleccionados que no participan en una discusión puramente climática. Esto se detalla en la sección 6.2.

## 2.2. Base de datos de políticos

A lo largo del trabajo, estudiaremos la posibilidad de existencia de una correlación entre una postura política y una postura climática. Para analizar la postura política (o dimensión política, como la llamaremos más adelante), utilizaremos una base de datos de políticos en Twitter.

Esta base de datos, descrita en [15], tiene información de cuentas de Twitter (Ids, usernames) asociadas a políticos electorales procedentes de 26 países. Esta información fue recolectada entre septiembre de 2017 y agosto de 2021 y está disponible de manera gratuita en [TwitterPoliticians.org](https://twitterpoliticians.org).

## 3. Métodos

### 3.1. Latent Ideology

#### 3.1.1. Evolución histórica

El concepto de Latent Ideology, que de ahora en más llamaremos LI, fue introducido por Barberá en el 2014 en [16], aunque esta basado en el concepto de “Modelos de Espacios Latentes” introducido por Hoff en [17].

Hoff asume que la posiciones ideológicas o políticas de un grupo de individuos en una red pueden ser inferidas estudiando las interacciones entre estos individuos con otros sujetos, puesto que en este tipo de redes existe un alto grado de homofilia, entendiendo por esto al fenómeno en el cual los individuos tienden a establecer conexiones y relaciones con otros individuos que comparten características similares. En este modelo se asume que los nodos en una red están representados por puntos en un espacio de dimensionalidad inferior llamado “Espacio latente”. La idea principal es que las conexiones entre los nodos en la red se pueden entender a partir de la proximidad de los puntos en este Espacio Latente. Es decir, nodos que están cerca en este espacio, tienen una mayor probabilidad de estar conectados entre sí en la red.

Inspirado en este concepto, Barberá estimó las posiciones políticas de usuarios en el Espacio Latente a partir de una red de seguidores en Twitter en donde participan políticos correspondientes a 6 países, presentando otro enfoque para estimar las posiciones políticas de los usuarios: el “Bayesian ideal point”. En este enfoque (que se detalla en [16]), se modela la probabilidad  $P_{ij}$  de que un usuario  $i$  siga a un usuario político  $j$ . La idea entonces es que existe una relación entre la probabilidad  $P_{ij}$  y la distancia entre usuarios en un espacio latente unidimensional. Por ende, modelando  $P_{ij}$  podemos construir un “Espacio Latente Ideológico” como el propuesto por Hoff.

El problema con esta forma de calcular el Espacio Latente Ideológico es que es computacionalmente ineficiente para grandes redes, como con las que se trabaja usualmente en redes sociales [18]. Es por eso que se introduce el uso del “Corres-

pondence analysis” para calcular la distribución de usuarios en un espacio latente. Este enfoque fue introducido nuevamente por Barberá et. al. en [18]. En este paper se utiliza, nuevamente, una red de seguidores y se estudian una serie de eventos polarizados socialmente. En 2021, Flamino et. al [19] utilizan el LI con correspondence analysis, pero aplicado a una red de retweets en el contexto de elecciones políticas en EEUU.

Finalmente, en Baronchelli et. al [1] se aplica el método de LI con correspondence analysis en torno a la discusión climática generada por las COPs. Esta tesis esta inspirada en lo estudiado en este paper.

#### 3.1.2. Correspondence analysis (CA)

Consideremos una red bipartita, la cual se puede representar con una matriz de adyacencia bipartita, en donde ambas capas de la red corresponden a las filas y las columnas de esta matriz, respectivamente. Cada elemento de esta matriz indica la interacción entre un objeto de una capa con un objeto de la otra capa. Mediante técnicas de reducción de dimensionalidad se pueden identificar grupos de objetos de una misma capa que son similares entre si pero que no necesariamente interactúan entre si. Para medir similaridad entre objetos de una capa, introducimos el método “Latent Ideology”, que detallaremos matemáticamente a continuación.

Sea la matriz de adyacencia bipartita  $\mathbf{A} \in \mathbb{R}_{n \times m}$  en donde cada elemento de matriz indica una interacción pesada entre un elemento de las filas y un elemento de las columnas. Teniendo en cuenta que las filas y las columnas de  $\mathbf{A}$  pueden representar a un conjunto cualesquiera de objetos, llamaremos “targets” al conjunto de objetos que se ven representados por las filas de  $\mathbf{A}$  y “sources” al conjunto de objetos que se ven representados por las columnas de dicha matriz.

Lo primero que hacemos es normalizar la matriz. Definimos entonces la matriz  $\mathbf{P}$  normalizada como

$$\mathbf{P} = \mathbf{A} \frac{1}{\sum_{i,j} a_{ij}} \quad (3.1)$$

Definimos ahora los vectores  $\mathbf{r}$  y  $\mathbf{c}$  que llamamos “vectores de masas” de las filas y las columnas:

$$\begin{aligned} \mathbf{r} &= \mathbf{P}_{n \times m} \mathbf{1}_{m \times 1} \\ \mathbf{c} &= \mathbf{1}_{1 \times n} \mathbf{P}_{n \times m} \end{aligned} \quad (3.2)$$

Cada elemento  $r_i$  de  $\mathbf{r}$  indica la probabilidad de que exista alguna interacción entre el target  $i$  con algún “source” y cada elemento  $c_j$  de  $\mathbf{c}$  indica la probabilidad de que

el “source”  $j$  interactúe con algún “target”. En una matriz de retweets de usuarios-influencers, como con la que trabajaremos nosotros,  $r_i$  indica la probabilidad de que un usuario  $i$  haga un retweet y  $c_j$  indica la probabilidad de que un influencer  $j$  sea retweeteado.

Definamos por último a las matrices diagonales asociadas a  $r$  y  $c$

$$\begin{aligned}\mathbf{D}_r &= \text{diag}(\mathbf{r}) \\ \mathbf{D}_c &= \text{diag}(\mathbf{c})\end{aligned}\tag{3.3}$$

Con las matrices definidas anteriormente, la técnica de CA estandariza a la matriz  $\mathbf{P}$  mediante el uso de “residuos estandarizados” [20]. Se define entonces a la matriz  $\mathbf{P}$  estandarizada o matriz de residuos  $\mathbf{S}$  como:

$$\mathbf{S} = \mathbf{D}_r^{-1/2}(\mathbf{P} - \mathbf{r}\mathbf{c})\mathbf{D}_c^{-1/2}\tag{3.4}$$

Los elementos de matriz de  $\mathbf{S}$  cuantifican la diferencia entre los datos reales y el valor esperado bajo la suposición de que no hay relación entre las filas y las columnas (o los targets y las sources). En este caso, el valor esperado (o matriz de esperanza) es la matriz  $\mathbf{r}\mathbf{c}$ .

El siguiente paso consta en reducir la dimensionalidad del método. Para ello, hacemos una descomposición en valores singulares (SVD) truncada a dimensión  $k$ , considerando los  $k$  valores singulares mas grandes. Se llama “valores singulares” a la raíz de los autovalores de  $S^T S$ . Hacer SVD es entonces proponer la descomposición:

$$\mathbf{S} = \mathbf{U}\mathbf{D}_k\mathbf{V}^T\tag{3.5}$$

con  $\mathbf{U} \in \mathbb{R}_{m \times k}$ ,  $\mathbf{V}^T \in \mathbb{R}_{k \times n}$  unitarias, es decir:  $\mathbf{U}\mathbf{U}^T = \mathbf{V}\mathbf{V}^T = \mathbf{1}$  y  $\mathbf{D}_k \in \mathbb{R}_{k \times k}$ . En nuestro caso, la matriz  $\mathbf{U}_{m \times k}$  contiene información de los targets en un espacio de dimensión  $k$ , y la matriz  $\mathbf{V}_{n \times k}$  contiene información las sources, también en un espacio de dimensión  $k$ . En particular, siguiendo los procedimientos de [19] y [1], consideraremos un espacio latente unidimensional, por lo que haremos una reducción dimensional con  $k = 1$ .

Notar que como  $\mathbf{U}$  contiene información de las filas de  $\mathbf{S}$ , y  $\mathbf{V}$  contiene información de las columnas de  $\mathbf{S}$ , para proyectar la información del SVD truncado en la capa de las filas y las columnas, definimos las coordenadas estandarizadas  $\mathbf{X}$  e  $\mathbf{Y}$ , donde:

$$\begin{aligned}\mathbf{X} &= \mathbf{D}_r^{-1/2}\mathbf{U} \\ \mathbf{Y} &= \mathbf{D}_c^{-1/2}\mathbf{V}\end{aligned}\tag{3.6}$$



Las coordenadas de la matriz  $\mathbf{X}$  representan las componentes de las interacciones de los usuarios en las direcciones principales escalada al intervalo  $[-1, 1]$ . Los valores correspondientes a la primera componente principal los llamaremos “Latent Ideology” o “score” de los targets. El “score” de las sources, si bien se puede estimar con  $\mathbf{Y}$ , se calculará de otra forma, según [1, 19]. Esto se detallará en la siguiente sección. En la practica, tendremos una matriz bipartita  $\mathbf{A}$  de usuarios-influencers (target-sources) por lo que el output del método es una lista de scores asociados a cada usuario.

#### Scores de sources

Dado el score calculado para cada target (usuarios) según la metodología desarrollada más arriba, definimos el score de las sources (influencers, medios, etc) como el promedio ponderado por la cantidad de interacciones de los scores de los targets que interactuaron con cada source. Entonces, si  $n'$  targets interactuaron con el source  $j$ , el score asociado a  $j$  estará dado por:

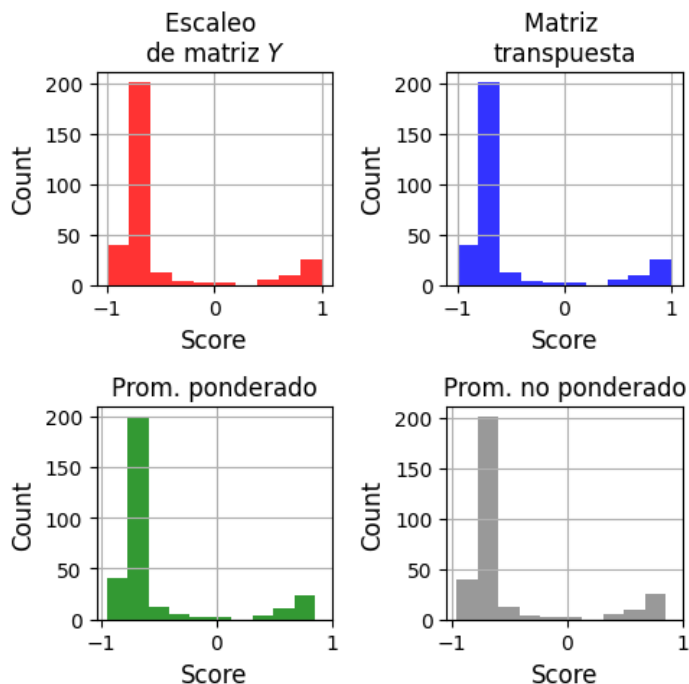
$$score(j) = \frac{\sum_{i=1}^{n'} score(i)\omega(i)}{\sum_{i=1}^{n'} \omega(i)} \quad (3.7)$$

donde  $\omega(i)$  es el elemento de matriz  $a_{ij}$  de la matriz de adyacencia  $\mathbf{A}$ .

Además de que el score de las sources se puede calcular como el promedio ponderado de los scores de los targets (como se detalló recién), también se puede definir como el promedio sin ponderar de los scores de los targets, con el escaleo de la matriz  $\mathbf{Y}$ , o bien con el uso de la matriz  $\mathbf{A}^T$  como input para el análisis de Correspondence Analysis (CA). La figura 3.1 muestra una comparación de todas las formas mencionadas de cálculo de los scores de las sources. Veamos estas cuatro formas diferentes de calcular el score de las sources con los datos de la COP26. Quiénes son las sources (o influencers) en la COP26 y cómo llegamos a esta distribución se discutirá en la sección 4.

Observamos en el gráfico de la distribución de scores que todas las diferentes formas de calcular los scores de las sources son similares. Tanto el cálculo del score utilizando el promedio ponderado como el promedio no ponderado de los scores de los targets produce resultados similares en nuestro conjunto de datos. Calcular el score directamente a partir de la matriz  $\mathbf{Y}$ , como se define en la ecuación 3.6, o introducir la matriz de adyacencia transpuesta como input al método produce resultados idénticos, como era de esperarse.

Existen diferencias entre el score calculado mediante el promedio ponderado de los scores de los targets y los scores calculados mediante la matriz  $\mathbf{Y}$ , pero la forma de la distribución es la misma. Concluimos que si una distribución está polarizada



**Figura 3.1:** Distribuciones de scores de las sources (o influencers) para el ejemplo de la COP26, para varias definiciones en el cálculo de score de sources.

tras el cálculo de los scores de las sources, seguirá estando polarizada para cualquier otra definición.

Dado que nuestro objetivo es detectar polarización en las discusiones, consideraremos análoga cualquier forma de cálculo de los scores de las sources. Siguiendo el enfoque de trabajo de [1, 19], tendremos en cuenta la definición de los scores de las sources como el promedio ponderado de los scores de los targets.

### 3.1.3. Parámetros del modelo

Teniendo en cuenta que se parte de una red social, para construir una red bipartita a partir de esta red es necesario identificar dos capas en la red original. Definimos como una de las capas a los  $m$  nodos más relevantes, a los cuales, siguiendo la notación de 3.1.2, llamamos “sources”.

Definimos en este contexto como relevante a los nodos con mayor centralidad de grado de entrada en la red dirigida original. En la sección 6.3, exploraremos otras definiciones de centralidad para identificar sources. La otra capa la conforman los nodos (o “targets”) que han interactuado con alguno de estas  $m$  sources.

El parámetro  $m$  es el primer parámetro del modelo. En la representación de la red como una matriz de adyacencia bipartita,  $m$  representa la cantidad de columnas de la matriz.

El segundo parámetro del modelo, el parámetro  $n$ , es una condición a los targets del modelo. Solo serán tenidos en cuenta aquellos targets que hayan interactuado con al menos  $n$  de las  $m$  sources que definimos previamente. Siguiendo el enfoque de [1, 19], solo consideraremos targets que hayan interactuado con al menos  $n = 2$  sources. Para el caso particular de una red de retweets, esto implica que solo tendremos en cuenta usuarios que hayan interactuado con al menos 2 de los  $m$  usuarios con mayor centralidad de grado.

Por ultimo, el tercer parámetro del modelo, el parámetro  $k$ , es una cota a las interacciones totales de un target hacia un source. De esta forma, se limita la presencia de targets muy activos. En el caso de una red de retweets, por ejemplo, el parámetro  $k$  limita la presencia de usuarios que realizan muchos retweets.

Cabe destacar que, dado que el objeto de estudio de nuestro trabajo es el mismo que del trabajo de Baronchelli et. al. [1], consideraremos el mismo valor del parámetro  $m$ . Esto es  $m = 300$  sources. La justificación en la elección de este parámetro, así como también del parámetro  $n \geq 2$  será abordada en el apéndice 6.1.

#### 3.1.4. Full SVD y Randomized SVD


El método de Latent Ideology con Correspondence Analysis tiene una ventaja principal sobre el Bayesian Ideal Point propuesto por Barberá en 2014: su eficiencia computacional.

Teniendo como objetivo maximizar esta eficiencia, hay que tener en cuenta que el proceso mas demandante computacionalmente en el calculo de Correspondence Analysis es el de la reducción de dimensionalidad con SVD. Para optimizar este proceso, se puede utilizar la técnica del cálculo de SVD truncado, que consiste en calcular solo las  $k$  componentes principales de la matriz de entrada. Esto se logra a través del uso de Randomized SVD, una técnica que utiliza métodos aleatorios para obtener una aproximación de la matriz de entrada con una precisión controlada [21].

Randomized SVD es un proceso iterativo que utiliza la técnica del Power Iteration -el cual consiste en iterar una multiplicación entre una matriz y un vector inicial aleatorio, y normalizar el resultado en cada iteración- para obtener los valores y vectores singulares de la matriz de entrada. La idea es entonces perder la menor cantidad de información posible en nuestros datos, ganar tiempo de computo y hacer posible el calculo del LI para matrices grandes en cualquier computadora.

Teniendo acceso al cluster de computadoras del SoPhy Lab, podemos ver, para nuestra base de datos, cuantas iteraciones (Power Iterations) debemos hacer para perder la menor cantidad de información posible en comparación con el calculo de Full SVD. Para ello, podemos analizar la variación en la distancia euclídea entre los

vectores de scores de los targets  $\mathbf{X}$  (usuarios de Twitter en este caso) en la matriz de mayor dimensión que utilizaremos: la matriz de adyacencia de la COP26, con un tamaño de  $184700 \times 300$ . Esta información se encuentra representada en la figura 3.2 Se nota que a partir de 15 iteraciones, Randomized SVD converge a Full SVD, puesto que la distancia euclídea entre los vectores de scores es estable.



**Figura 3.2:** Distancia euclídea entre los vectores de scores de usuarios participantes de la COP26 calculados mediante el método de Latent Ideology con Correspondence Analysis con Full SVD y con Randomized SVD con Power Iterations para varias iteraciones.

En la práctica siempre utilizaremos el cálculo de Full SVD para LI. No obstante, es importante conocer el orden de las iteraciones necesarias para la convergencia del Randomized SVD, ya que esta técnica no solo acelera los tiempos de cómputo, sino que también permite procesar los datos en dispositivos tradicionales como laptops y PCs, sin necesidad de contar con recursos de hardware específicos.

### 3.1.5. Ejemplo de aplicación

Consideremos una matriz de adyacencia bipartita  $\mathbf{A}$  que tiene la siguiente forma:

$$A = \begin{pmatrix} 5 & 5 & 0 & 0 \\ 1 & 0 & 1 & 1 \\ 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 1 \end{pmatrix}$$

Esta matriz puede ser representada como un esquema de interacciones tal como se muestra en la tabla 3.1

	source 0	source 1	source 2	source 3
target 0	5	5	0	0
target 1	1	0	1	1
target 2	1	0	0	0
target 3	1	1	0	0
target 4	0	0	1	1

**Tabla 3.1:** Representación de la matriz de adyacencia bipartita de ejemplo que llamamos  $\mathbf{A}$


Cada elemento de matriz de  $\mathbf{A}$  corresponde a una interacción pesada entre un elemento de la capa de los *targets* y un elemento de la capa de las *sources* de una red bipartita. Esta matriz bipartita la podemos visualizar en un grafo, tal como el que se muestra en la izquierda de la figura 3.3.

Para aplicar el método de LI, usualmente [1, 19] se considerarán en la discusión sólo a los targets que hayan interactuado con al menos 2 de las sources. Esto es porque para asignarle un score a un target, necesito conocer su espectro de interacciones y no puedo construir un espectro con solo una interacción con una source. Como vimos en la sección 3.1.3, esto quiere decir que imponemos el valor  $n \geq 2$ .

Tras considerar este valor de  $n$ , la red bipartita final, a cuya matriz de adyacencia le aplicaremos el método, se observa a la derecha de la figura 3.3. Cabe destacar que dada la poca cantidad de interacciones y la baja dimensión de la matriz  $\mathbf{A}$ , no impondremos restricciones ni sobre la cantidad de sources  $m$ , ni sobre la cantidad de total de interacciones  $k$ . Notar que, tras el filtrado, el target 2 no aparece en el grafo de la derecha de la figura 3.3.

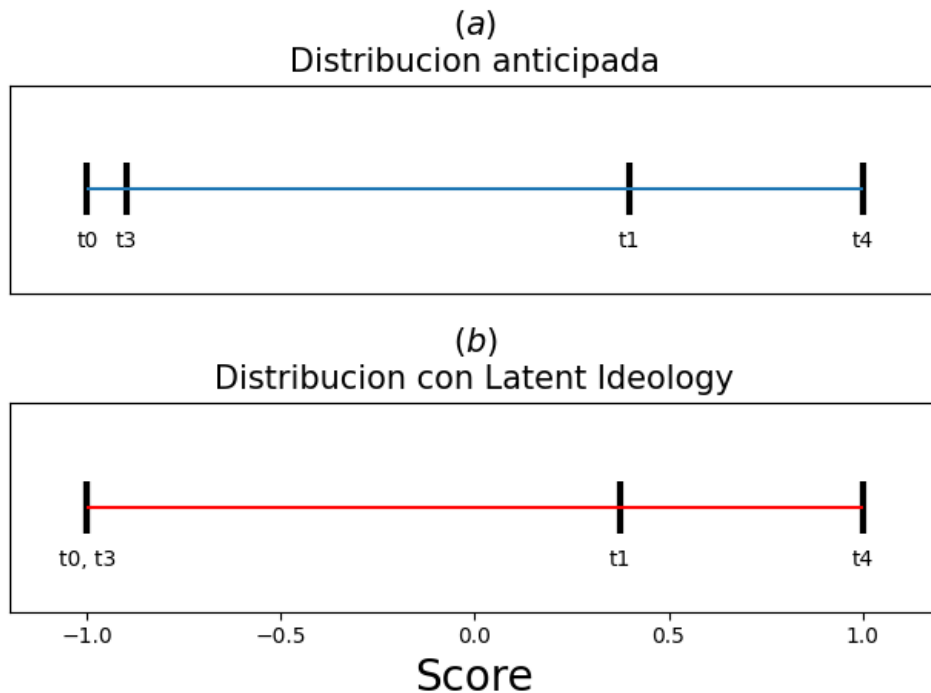
Podemos interpretar de antemano como se agruparán los targets tras el calculo del score sin necesidad de aplicar el método. Se espera que los targets  $t0$  y  $t3$  tengan score similares ya que interactúan con las mismas sources, aunque  $t0$  lo haga con mayor frecuencia debido al peso de la interacción. Por otro lado, el target  $t4$  no comparte ninguna source en común con  $t0$  y  $t3$ , por lo que se espera que el score de  $t4$  sea diferente al de  $t0$  y  $t3$ . El target  $t1$ , por su parte, comparte sources en común con  $t0$ ,  $t3$  y  $t4$ , pero comparte más sources con  $t4$  que con el resto de los targets. Por lo tanto, se esperaría que el score de  $t1$  esté cerca del score de  $t4$ , pero no muy lejos del score del grupo  $\{t1, t3\}$ . Los scores esperados se representan cualitativamente en el gráfico (a) de la figura 3.4.

Calculemos ahora el score de los targets con el método de LI. Para esto, dada la matriz  $\mathbf{A}'$  (la matriz  $\mathbf{A}$  tras aplicar la condición  $n \geq 2$ ) aplicamos lo visto en la sección “Correspondence Analysis”: normalizamos, estandarizamos, hacemos SVD



**Figura 3.3:** Grafos asociados a la matriz de ejemplo  $\mathbf{A}$  representada en la tabla 3.1. Cada link entre nodos tiene un peso dado por el elemento de matriz de  $\mathbf{A}$  que se representa por el grosor del link. A la izquierda el grafo sin filtrado y a la derecha, el grafo considerando nodos con grado mayor o igual a 2.

y proyectamos sobre la dimensión con valor singular mas grande. La distribución de scores puede verse en el gráfico (b) de la figura 3.4.



**Figura 3.4:** (a) Scores esperados (por inspección visual de la tabla 3.1 y las redes bipartitas de la figura 3.3) de los targets, dada la matriz  $\mathbf{A}$ . (b) Scores de los targets calculados con el método de Latent Ideology.

Efectivamente, la distribución de scores que anticipamos por inspección visual, es similar a la distribución de scores calculada a través del método de LI. Es importante

destacar que el score de los targets  $t0$  y  $t3$  es idéntico en lugar de “similar” como se había previsto. Esto se debe a que ambos targets tienen el mismo espectro de sources y, gracias a la estandarización, el peso de las interacciones no tiene influencia en el cálculo del score final de estos targets.

## 3.2. Dip Test de Hartigan

El test de Hartigan (también conocido como Dip Test) es una prueba estadística no paramétrica utilizada para determinar si una distribución univariante de datos es unimodal o multimodal [22]. El objetivo del test es identificar si los datos tienen una tendencia central clara o si hay múltiples modas.

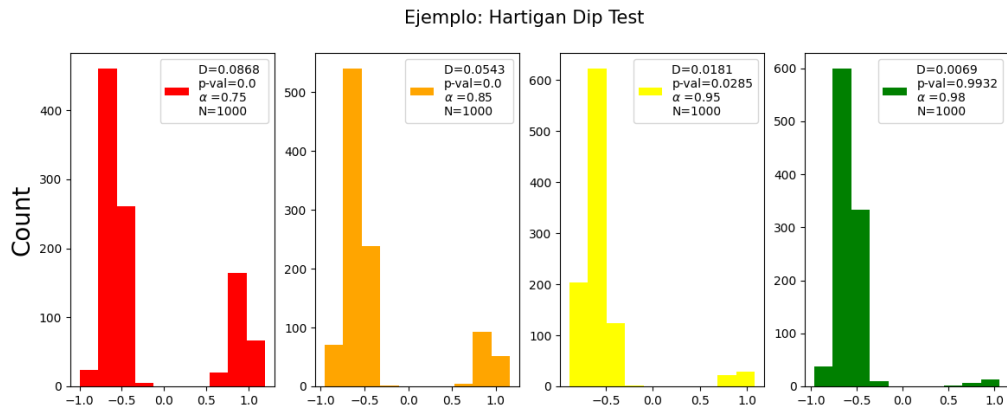
En el test de Hartigan se calcula el valor del “dip” o *D-estadística* que se refiere a la diferencia entre la función de densidad empírica (EDF) y la función de densidad unimodal que mejor se ajusta a los datos. Si los datos son unimodales, el dip será pequeño, lo que indica que la EDF y la distribución unimodal son similares. Si los datos son multimodales, el dip será grande, lo que indica que la EDF tiene múltiples picos y no se ajusta bien a una distribución unimodal. Usualmente, se compara el dip entre un conjunto de distribuciones para analizar cual de ellas es más multimodal.

En el test se calcula el dip y luego se compara ese valor con los dips obtenidos de muestras aleatorias de datos de una distribución unimodal. Si el valor del dip es significativamente mayor que los dips obtenidos de las muestras aleatorias, se rechaza la hipótesis nula en favor de la hipótesis alternativa de que los datos son multimodales. Es por ello que a cada valor de dip, está asociado un p-valor. En este trabajo, usaremos como cota para rechazar la hipótesis nula un p-valor igual a 0,01. Entonces, si  $p \leq 0,01$ , los datos son muy probablemente multimodales y la hipótesis nula debe ser rechazada. Por otro lado, si  $p > 0,01$ , no hay suficiente evidencia para rechazar la hipótesis nula, por lo que los datos pueden seguir una distribución unimodal.

Para darnos una idea de como varía el dip en función de la distribución, en la figura 3.5 se muestran varias distribuciones, con distinto grado de bimodalidad  $\alpha$ , y los respectivos valores  $D$  y  $p$  asociados a cada distribución. Definimos el grado de bimodalidad  $\alpha$  de una distribución de  $N$  elementos como

$$\alpha = \frac{N1}{N2} \tag{3.8}$$


en donde  $N1$  y  $N2$ , con  $N = N1 + N2$ , son la cantidad de elementos en las modas de cada distribución. Un valor de  $\alpha = 0,5$  implica completa bimodalidad en la distribución. Por el contrario, un valor de  $\alpha = 1$  implica completa unimodalidad. Efectivamente, al aumentar  $\alpha$ , disminuye la D-estadística y aumenta el p-valor.



**Figura 3.5:** Distribuciones con distintos grados de desbalance  $\alpha$ , para distribuciones con  $N = 1000$  muestras.

En la práctica, es común trabajar con distribuciones de scores que presentan un alto grado de desbalance. En el caso de la COP21, en particular, se observa que la discusión es menos polarizada que en la COP26, lo que se refleja en la cantidad de personas que obtienen un score mayor o menor a 0.

Como queremos entender la significancia del Dip Test en estos casos, consideraremos un caso similar al de la COP21, creando una distribución con un cociente de desbalance alto. En la COP21, el cociente de desbalance real es igual a 0,98. Fijando  $\alpha$  en este valor, podemos calcular el valor de la D-estadística y el p-valor asociado para distribuciones de distinto tamaño. Es decir, podemos ver como varía la D-estadística y el p-valor en función de  $N$  para una distribución con  $\alpha = 0,98$ . Esto se muestra en la figura 3.6



**Figura 3.6:** A la izquierda, variación de la D-estadística en función de  $N$  para un desbalance  $\alpha = 0,98$  fijo. A la derecha, variación del p-valor en función de  $N$ . En rojo,  $p = 0,01$ , valor que consideraremos como umbral para identificar multimodalidad.

Notar que para distintos valores de  $N$ , dado este valor de  $\alpha$ , la D-estadística se estabiliza para  $N = 2000$ . Por otro lado, el p-valor, que nos indica si debemos



rechazar o no la hipótesis de unimodalidad es menor a 0,01 a partir de  $N = 12000$ .

Entonces, para la distribución de la COP21 con  $\alpha = 0,98$ , si bien a simple vista uno estaría motivado a rechazar la hipótesis de multimodalidad, hay que tener en cuenta la cantidad de elementos de la distribución, pues el p-valor es el que determina si podemos rechazar o no la hipótesis de unimodalidad.

## 3.3. Análisis de tópicos con BERT

BERT (Bidirectional Encoder Representations from Transformers) es una red neuronal multicapa de aprendizaje profundo basada en la arquitectura de *transformers* publicada por Jacob Devling et al. en 2018 [23, 24]. BERT utiliza un mecanismo de atención que aprende las relaciones contextuales entre las palabras (o subpalabras) de un texto. A diferencia de otros modelos considerados direccionales, que leen el texto de entrada secuencialmente (de izquierda a derecha o de derecha a izquierda), BERT lee toda la secuencia de palabras a la vez. Esta característica permite al modelo aprender el contexto de una palabra basándose en todo su entorno (tanto a la izquierda y como a la derecha de la palabra).

BERT se utiliza en una amplia gama de tareas de NLP (procesamiento del lenguaje natural) como la clasificación de texto, la generación de texto, la traducción automática, el análisis de sentimientos, entre otros. En particular, nosotros utilizaremos a BERT para la detección de tópicos en un conjunto de tweets.

El análisis de tópicos es una técnica utilizada en NLP y minería de texto para descubrir y modelar los temas latentes en un conjunto de documentos [25]. La herramienta para el análisis de tópicos con BERT que utilizaremos es BERTopic [26]. BERTopic hace detección de tópicos siguiendo tres pasos. En primer lugar, cada documento (en este trabajo, tweets) se convierte en un “embedding” o vector mediante Sentence-BERT (SBERT). SBERT permite convertir oraciones y párrafos en representaciones de vectores densos utilizando modelos de lenguaje pre-entrenados. En segundo lugar, se aplican técnicas de reducción de dimensionalidad y clustering a los datos. Por último, a partir de los clusters de documentos, se extraen representaciones de tópicos utilizando una variación de la técnica de TF-IDF: la variante class-based, también llamada c-TF-IDF, que explicaremos a continuación.

Un vector TF-IDF (Term Frequency-Inverse Document Frequency) es una representación numérica de un documento de texto. TF-IDF combina dos conceptos: la frecuencia del término (TF) y la frecuencia inversa del documento (IDF) [27]. La frecuencia del término (TF) mide la importancia de un término (o palabra) en un documento (o texto) en particular. Se calcula dividiendo el número de veces que

aparece un término en un documento entre el número total de términos en ese documento. La frecuencia inversa del documento (IDF) mide la relevancia de un término en un conjunto de documentos. Se calcula de la siguiente forma:

$$IDF(t) = \log\left(\frac{N}{n_t + 1}\right) \quad (3.9)$$

en donde  $N$  es el número total de documentos en el corpus y  $n_t$  es la cantidad total de documentos en el corpus que contienen el término  $t$ . El vector TF-IDF asigna a cada término en un documento un valor numérico que representa su importancia relativa en ese documento y en el conjunto de documentos en general

En la variante c-TF-IDF, se agrupan los documentos en diferentes clases. Luego, el cálculo del TF e IDF se realiza para cada clase en lugar de para el conjunto completo de documentos. En nuestro caso, cada clase es un cluster de documentos. Particularmente, nosotros tendremos clusters de tweets. Luego, todos los tweets en un cluster se tratan como un único documento y se encuentra un vector TF-IDF para cada cluster. Por último, considerando las primeras  $n$  palabras más relevantes en cada cluster, es posible asociar un tópico a cada cluster.

## 3.4. Construcción y análisis de redes de retweets

Dada la base de datos descrita en la sección 2, disponemos de un dataset de tweets, retweets, quotes y comentarios. Centrándonos solo en los retweets, dado que tenemos acceso al los IDs de los usuarios que crearon el tweet original y que hicieron el retweet, podemos crear un dataset de interacciones (o edgelist) entre IDs. A su vez, como el ID es una identificación única para cada usuario, podemos contabilizar la cantidad de interacciones totales de un usuario, por lo que podemos armar una red de retweets dirigida con links pesados.

### 3.4.1. Detección de comunas en la red

Dada la red de retweets, podemos detectar comunas dentro de ella. El objetivo de la detección de comunas es identificar grupos de nodos en la red que estén densamente conectados entre sí, mientras que existe una conectividad más limitada con los otros nodos de la red. Estos grupos o comunas podrían llegar a representar agrupaciones de nodos con características similares.

Para detectar comunas dentro de la red, utilizaremos el Método de Louvain [28, 29]. Este es un proceso iterativo que en cada paso maximiza una cantidad definida como “modularidad de la red” con el objetivo de encontrar la partición óptima de la red en comunidades.

La modularidad  $Q$  es una medida que cuantifica la calidad de una partición de una red en comunas al comparar la densidad de conexiones dentro de las comunas en relación con las conexiones entre comunas. Esta se calcula comparando la distribución real de conexiones dentro de una red con un modelo nulo. La forma de  $Q$  es la siguiente:

$$Q = \frac{1}{2m} \sum_{i,j} \left( A_{ij} - \frac{k_i k_j}{2m} \right) \delta(c_i, c_j) \quad (3.10)$$

donde  $A_{ij}$  es el peso entre los nodos  $i$  y  $j$ ,  $k_i$  y  $k_j$  son respectivamente los grados de los nodos  $i$  y  $j$ ,  $m$  es el número total de conexiones en la red,  $c_i$  y  $c_j$  son las comunidades a las que pertenecen los nodos  $i$  y  $j$ , y  $\delta(c_i, c_j)$  es una función que toma el valor 1 si los nodos  $i$  y  $j$  pertenecen a la misma comunidad y 0 en caso contrario.

El valor de  $Q$  varía entre -1 y 1, donde un valor positivo indica una estructura de modularidad más fuerte que la esperada al azar. Un valor cercano a 1 sugiere una red altamente modular, mientras que un valor cercano a 0 indica una partición similar a la esperada en una red aleatoria.

La idea del método de Louvain es comenzar definiendo a cada nodo como su propia comuna para después comenzar con el proceso iterativo:

- Para cada nodo se evalúa la ganancia de modularidad al moverlo a la comuna de uno de sus vecinos. El nodo se mueve a la comuna que maximice la ganancia de modularidad.
- Se crea un nuevo grafo en donde los nodos representan las comunas obtenidas en el paso anterior.
- Se repite el proceso hasta que no se pueda obtener una ganancia de modularidad adicional al mover los nodos entre comunas. Una vez que no se puede maximizar más  $Q$  se llega a la configuración final.

#### 3.4.2. Homofilia de la red

Otro análisis relevante que haremos en este trabajo cuando trabajemos con redes de influencers (sección 4.3.2) es el cálculo de la homofilia de la red. La homofilia es la tendencia de los nodos a conectarse con otros nodos que son similares en ciertas características o atributos. En otras palabras, la homofilia implica que los nodos tienden a estar más conectados entre sí cuando comparten características similares.

En general, que dos nodos sean similares puede implicar que compartan intereses, ideologías, afiliaciones políticas o demográficas, etc [30]. En particular, en las redes

de influencers con las que trabajaremos, consideraremos como atributo para calcular homofilia al score ideológico, definido mediante el método de LI de cada influencer. Veremos que influencers con score mayor a 0 tienen tendencia a interactuar con otros influencers con score similar y que lo mismo pasa para influencers con score menor a 0.

Existe un índice  $r$  de homofilia que se calcula utilizando el coeficiente de correlación de Pearson para medir la asociación entre los atributos de los nodos conectados en comparación con lo que se esperaría por azar. Matemáticamente el coeficiente  $r$  de Pearson asociado a la homofilia tiene la forma:

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum(x_i - \bar{x})^2 \sum(y_i - \bar{y})^2}} \quad (3.11)$$

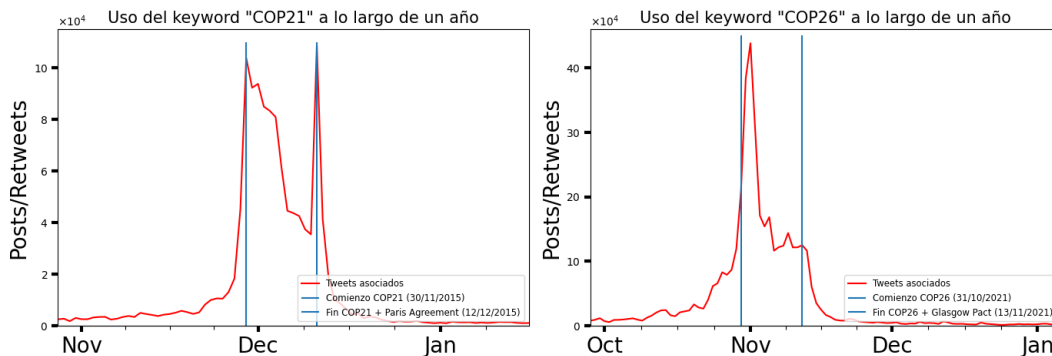
donde  $X_i$  y  $Y_i$  son los valores de los atributos de los nodos conectados,  $\bar{X}$  y  $\bar{Y}$  son las medias de los atributos respectivos, y  $n$  es el número de pares de nodos conectados.

Un valor de  $r$  positivo, indica que existe una mayor tendencia de los nodos a conectarse con otros que comparten características similares. Por otro lado, un valor de  $r$  es cercano a cero o negativo, indica una menor asociación entre los atributos de los nodos conectados [31].

## 4. Resultados

### 4.1. Propiedades generales del dataset

Estudiamos la evolución del uso de las keywords “COP21” y “COP26” a lo largo del tiempo. Para esto, establecemos un periodo temporal de 1 año, comenzando 6 meses antes del inicio de la conferencia, y contabilizamos los tweets originales y retweets que involucran el uso de estas keywords. Para una mejor visualización de los datos en el periodo de la conferencia, en la figura 4.1 se acorta la ventana temporal a un mes antes y un mes después del inicio de la conferencia.



**Figura 4.1:** Uso las keywords “COP21” (izquierda) y “COP26” (derecha) en Twitter, en función del tiempo. Las líneas verticales azules marcan el inicio y el final de las conferencias.

Notar que tanto en la COP21 como en la COP26, la discusión en Twitter respecto a la conferencia comienza a popularizarse pocos días antes del inicio de la conferencia. Análogamente, pocos días después de finalizada la conferencia, la cantidad de posts/retweets en relación con la conferencia decae rápidamente. Esto era de esperarse pues la vida media de estos eventos es del orden de días [32].

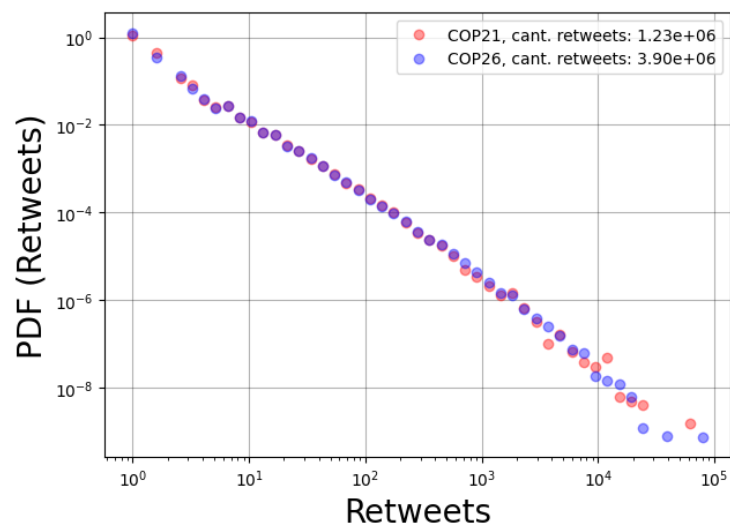
Observando la cantidad de posts y retweets para cada conferencia, se nota que en la COP26 hay mucha mas información que en la COP21. Esto puede deberse por un lado a un aumento en el uso de la red social Twitter desde la primer conferencia a la segunda, mientras por el otro un sesgo asociado al idioma de los tweets considerados: recordemos que la COP21 tuvo lugar en Francia y la COP26 tuvo lugar en Escocia y

solo consideramos tweets en inglés. Sin embargo, estudios recientes respecto al tema [1], en donde se analizan tweets en francés y en inglés, concluyen que la discusión es mucho mas masiva en la COP26 que en la COP21.

Otro detalle importante a destacar es el impacto generado por el Tratado de París en comparación al impacto generado por Pacto de Glasgow. Notar que hay un pico en la cantidad de posts y retweets en el día del firmado del acuerdo al final de la COP21, hecho que no ocurre en la COP26. Esto se debe a la popularidad del Tratado de París frente a los acuerdos firmados en años posteriores.

El Tratado de París fue un acuerdo altamente ambicioso que estableció, entre otras cosas, la intervención económica de los países desarrollados para la implementación de medidas de mitigación y adaptación al cambio climático en los países en desarrollo [9]. Sin embargo, este conjunto de propuestas económicas no se había cumplido al momento de la conferencia COP26. Atribuimos la popularidad del Tratado de París a su ambición en términos económicos. Por otro lado, el Pacto de Glasgow [33] propuso medidas económicas menos ambiciosas, lo cual podría ser la razón de su menor alcance y popularidad.

Continuando con el análisis en la cantidad de posts y retweets en cada conferencia, podemos estudiar la cantidad de tweets originales en función de la cantidad de retweets asociados. Esto se observa en la figura 4.2.



**Figura 4.2:** Cantidad de retweets en relación con la función de densidad de probabilidad (PDF) de los retweets, es decir, en función del número de tweets originales, utilizando una escala logarítmica con binado logarítmico. Los datos corresponden a las conferencias COP21 y COP26.

Es importante señalar que, tal como se espera en este tipo de análisis, un número reducido de tweets recibe una gran cantidad de retweets, mientras que la mayoría de los tweets reciben pocos, asemejándose a una distribución libre de escala.

## 4.2. Polarización con Latent Ideology

A partir de nuestra base de datos, descrita en la sección 2, podemos construir matrices de adyacencia bipartitas<sup>1</sup> en donde cada elemento de matriz corresponde a una interacción entre las dos capas de la red bipartita asociada. En este trabajo, las capas están definidas de la siguiente manera: por un lado, se encuentran los  $m$  usuarios con mayor centralidad de grado de entrada (los  $m$  usuarios mas retweeteados), a los que llamamos “influencers” (o “sources” siguiendo la notación de 3.1.2), y por otro lado están el resto de los usuarios (o “targets”) que interactuaron con al menos  $n$  de estos  $m$  influencers.

Vamos a considerar los parámetros del modelo  $m = 300$ ,  $n \geq 2$  y no vamos a imponer restricciones sobre la cantidad máxima de retweets de usuarios a influencers. Es decir, no vamos a imponer restricciones sobre el parámetro  $k$ . La elección de estos parámetros se justifica en el apéndice 6.1.

Dadas estas matrices de adyacencia bipartitas, podemos aplicar el método de Latent Ideology. El resultado del método es una lista de scores para cada usuario y para cada influencer. Usuarios con score similar son usuarios que comparten muchas interacciones con los mismos influencers. Dado que el objeto de estudio de este trabajo es el estudio de polarización en temas climáticos, lo que buscamos es una discusión “ambientalista” dentro del debate de las COP. Veremos que para detectar esta discusión en particular, hace falta un filtrado manual de usuarios seleccionados bajo algún criterio. Este filtrado de usuarios se analiza en detalle para ambas conferencias en el apéndice 6.2

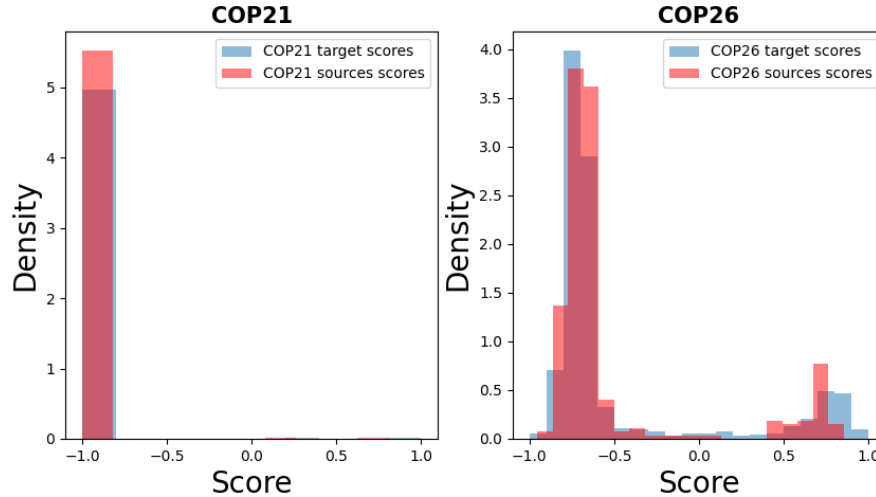
### 4.2.1. Caracterización de la discusión

Tras el filtrado de influencers seleccionados descrito en el apéndice 6.2 y al identificar una discusión ambientalista en el debate de las COP, al score de los usuarios lo podemos asociar, según [1], con la ideología climática de cada individuo.

Las distribuciones de scores de usuarios e influencers para las conferencias COP21 y COP26 se observan en la figura 4.3.

---

<sup>1</sup>La creación de matrices de adyacencia bipartita a partir de una red se hizo a través de la librería de Python detallada en el apéndice 6.4

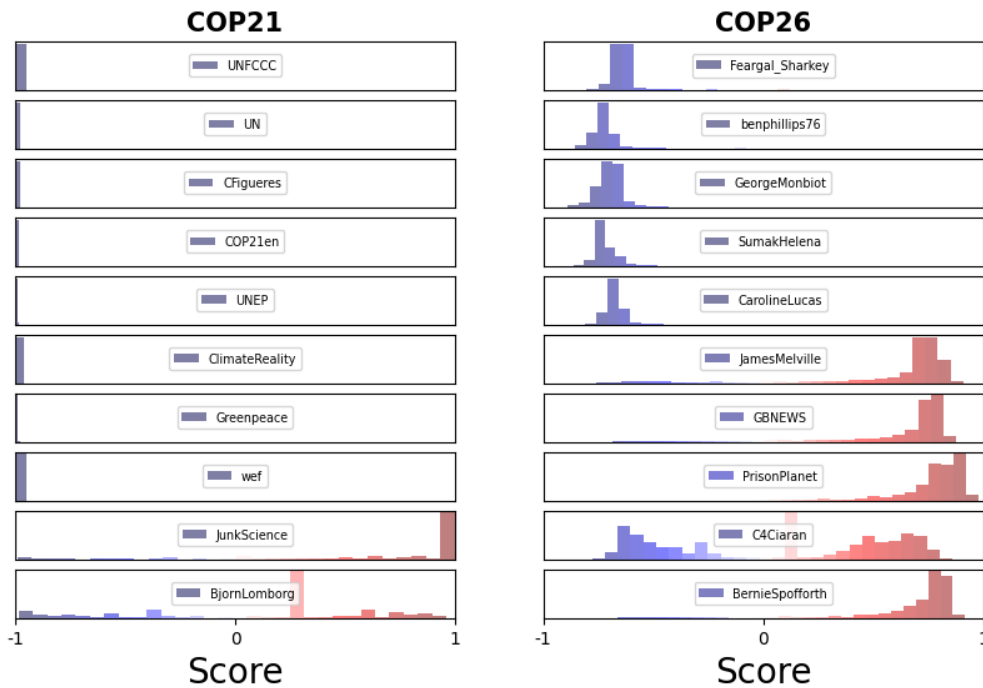


**Figura 4.3:** Espectro ideológico de la COP21 y de la COP26. A la izquierda, distribución de scores de usuarios e influencers para la COP21. A la derecha, distribución de scores de usuarios e influencers para la COP26.

Para la COP21 distinguimos un subgrupo con score cercano a 1 -la minoría- compuesta por 2 influencers: @BjornLomborg y @JunkScience. Tras el test de Hartigan descrito en la sección 3.2, la distribución de usuarios en esta conferencia presenta los valores  $D = 0,006$ ,  $pval = 1e - 16$  mientras que la distribución de influencers presenta los valores  $D = 0,02$ ,  $pval = 0,83$ . Para la distribución de scores de usuarios, dado que el p-valor es menor a 0,01 (la cota que habíamos impuesto en la sección 3.2), no podemos rechazar la hipótesis de unimodalidad. Para la distribución de influencers, por otro lado, sí la rechazamos.

En la distribución de la COP26, “la minoría” esta compuesta por 41 influencers, que detallaremos en la sección 4.2.2. Tras el test de Hartigan, obtuvimos los valores  $D = 0,039$ ,  $pval = 1e-16$  para la distribución de usuarios y  $D = 0,044$ ,  $pval = 3e-4$  para la distribución de influencers. En este caso, tanto como para la distribución de usuarios como para la distribución de influencers, rechazamos la hipótesis de unimodalidad. Notamos que la discusión en la COP26 es más polarizada que en la COP21. Esto se refleja en un valor más alto de la D-estadística de la COP26 en comparación con la de la COP21 tanto en la capa de los usuarios como en la capa de los influencers.





**Figura 4.4:** Distribución de score de los 10 influencers más retweeteados, repartidos de forma balanceada entre los subgrupos que definimos como la mayoría y la minoría, para las conferencias COP21 y COP26. Para la COP21, dado que la minoría está compuesta solo por 2 influencers, consideraremos los 8 usuarios más retweeteados del grupo mayoritario; estos corresponden a las primeras 8 distribuciones en la columna de la izquierda. Para la COP26, las primeras 5 distribuciones de la columna de la derecha corresponden al subgrupo de la mayoría y las últimas 5 corresponden al subgrupo de la minoría.

Podemos analizar cómo los influencers de cada conferencia obtuvieron los scores que tienen observando la distribución de scores de los usuarios que interactuaron con cada uno de ellos. En la figura 4.4, se muestra la distribución de scores de los 10 usuarios con mayor centralidad de grado de entrada, distribuidos de forma balanceada entre el subgrupo mayoritario (con score cercano a  $-1$ ) y el grupo minoritario (con score cercano a  $1$ ) para cada conferencia. Es importante destacar que en la COP21, dado que la minoría está compuesta solo por 2 influencers, consideraremos los 8 usuarios con mayor centralidad de grado de entrada del grupo mayoritario.

Notar que en la figura 4.4, en todas las distribuciones asociadas a influencers de la mayoría, los scores de los usuarios están siempre cerca de  $-1$ . Por el contrario, en los influencers de la minoría, aparecen influencers como @C4Ciaran en la COP26 o @BjornLomborg en la COP21 en cuyas distribuciones de scores están involucrados usuarios de la minoría y la mayoría. Analizando los tweets de estos individuos, concluimos que el score positivo de estos influencers tiene sentido desde una perspectiva de crítica hacia la conferencia. El estudio en detalle de estos individuos se detalla

en la siguiente sección.

### 4.2.2. Caracterización de los polos

En la COP21 hay dos influencers en la minoría: @BjornLomborg y @JunkScience. Estos tienen un claro enfoque anti-ambientalista, y se identifican a sí mismos como por fuera del discurso mainstream sobre el cambio climático. @JunkScience cita un artículo de Nature Climate Change que lo describe como “el negador de la ciencia climática más influyente” [34], mientras que @BjornLomborg hace referencia a su libro “Falsa Alarma: Cómo el pánico del cambio climático nos cuesta billones”. Estos dos usuarios son mencionados en [1] como los principales influencers de la minoría de la COP21, junto a @Tony\_Heller, que no aparece en nuestra base de datos.

En la COP26 hay 41 influencers en la minoría. De estos 41 influencers, encontramos que 5 están completamente ligados a una discusión climática con una perspectiva por fuera del discurso mainstream sobre el cambio climático: @BjornLomborg, @NetZeroWatch, @JunkScience, @HarryWilkinson y @EcoSenseNow. @NetZeroWatch es una organización comprometida con “las graves implicancias económicas y sociales de políticas climáticas y energéticas costosas y mal consideradas”, @HarryWilkinson pertenece a dicha organización y @EcoSenseNow es un influencer, cofundador de la organización no-gubernamental ambientalista *GreenPeace* que “actualmente se identifica como un ambientalista sensato enfocado en la ciencia y la lógica en lugar del sensacionalismo y el miedo”. Notar que 2 de estos influencers también pertenecen a minoría en la discusión de la COP21. Por otro lado, los 3 influencers restantes no están involucrados en discusión de la COP21.

Del resto de los influencers, identificamos 6 cuentas políticas (@laurenboebert, @SteveBakerHW, @Rob\_Kimbell, @TiceRichard, @danbloom1, @georgegalloway) y 3 medios británicos (GB News, The New York Post y spiked). Curiosamente, identificamos un subgrupo de influencers con puntos de vista críticos hacia las políticas sociales y sanitarias tomadas durante la pandemia del COVID-19 (@BernieSpofforth, @JamesMelville, @PrisonPlanet y @BareReality). La presencia de este subgrupo relacionado con la pandemia dentro de la minoría es consistente con los resultados encontrados de un subgrupo similar en el estudio de Baronchelli et al.

Podemos examinar el nivel de polarización dentro de la minoría al analizar la distribución de scores de estos 41 influencers después de eliminar al grupo mayoritario de la discusión y recalcular los scores de usuarios e influencers utilizando el método de LI. Observamos que en esta distribución, solo un influencer tiene un score menor a 0. Este influencer es @nypost, que corresponde al medio The New York Post. Además, solo 5 influencers se separan del pico con score cercano a 1. Procedemos

a seguir el proceso iterativo de eliminar influencers y recalcular el score con el LI. Después de 4 pasos en el proceso iterativo, notamos que en cada paso se desprende un influencer del pico principal. En base a esto, concluimos que la minoría no está polarizada en la COP26.

A diferencia de la minoría, al realizar el mismo proceso iterativo para la mayoría de la COP26, observamos la aparición de subgrupos con connotaciones geográficas: identificamos un subgrupo de influencers que hace referencia a políticas de Pakistán y otro subgrupo de individuos de Canadá. Estos subgrupos se separan en score del resto de influencers a medida que avanza el proceso iterativo. Concluimos que la aparición de estos subgrupos dentro de la “mayoría” no tiene nada que ver con una separación ideológica, sino que se trata de un sesgo geográfico.

### Análisis de tópicos en tweets

En esta sección nos enfocaremos en el análisis de los tweets de la minoría y la mayoría de la COP26. Recordemos que en la COP26 contamos con 41 influencers en la minoría, con un total de 430 tweets. Por otro lado, en la mayoría tenemos 259 influencers y 3500 tweets. Debido a esta gran cantidad de tweets abordaremos el problema mediante el enfoque del análisis de tópicos.

El análisis de tópicos se hará con la herramienta BERTopic [26], descrita en la sección 3.3. Dado que BERT es un modelo previamente entrenado con un amplio vocabulario, no es necesario el uso de stopwords pero, como queremos visualizar los resultados en el formato de nube de palabras (wordclouds), omitiremos algunas palabras frecuentes en los tweets: “COP26”, “COP”, “Glasgow”, “Scotland”, “conference”, etc. En la figura 4.5, se presentan wordclouds que muestran las palabras más relevantes asociadas a cada cluster identificado mediante el análisis de tópicos con BERT.

Identificamos 6 clusters en el análisis. En el cluster 0, encontramos las palabras “leaders” junto con referencias a los políticos Joe Biden (presidente de Estados Unidos), Nicola Sturgeon (PM de Escocia) y Boris Johnson (PM de Inglaterra). El cluster 1 muestra palabras como “photo”, “Sturgeon” y “selfie”, haciendo alusión a la polémica selfie entre Nicola Sturgeon y la activista climática Greta Thunberg. En el cluster 2, encontramos claras referencias con palabras como “jet”, “private” y “c02” que apuntan a la crítica hacia los participantes de la COP26 por utilizar aviones privados y generar contaminación ambiental. Por ejemplo, en este cluster aparece @GillianMcKeith, que escribe sobre la COP26, expresando textualmente en uno de sus tweets: *“Los aviones privados de los políticos de la COP26 emanan más C02 que lo que los escoceses emanan en un año”*.

## Tweets minoría COP26: Tópicos con BERT



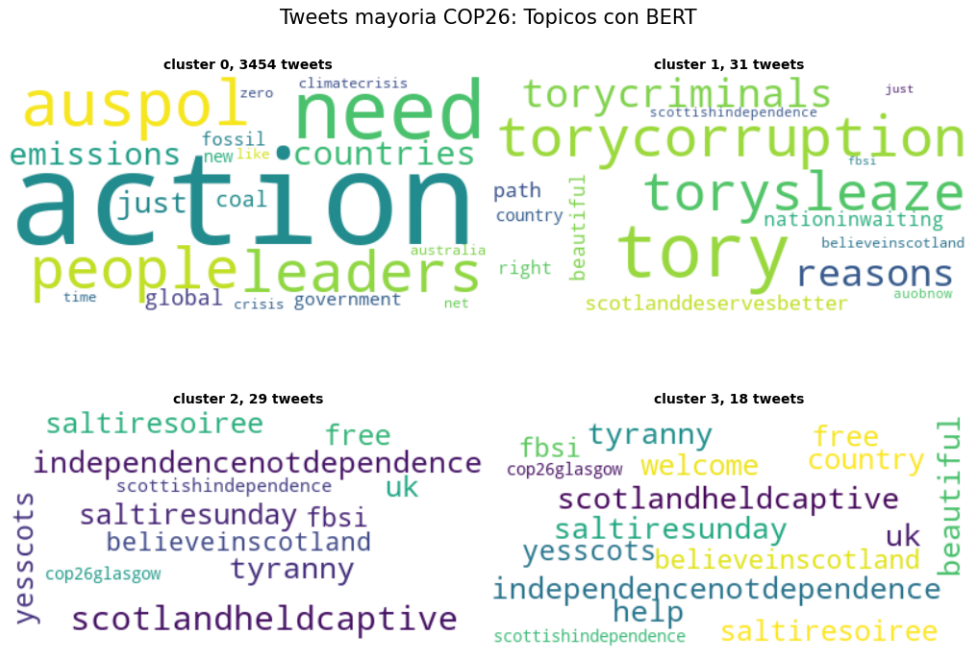
**Figura 4.5:** Nubes de palabras asociadas a cada cluster identificado mediante el análisis de tópicos con BERT en los tweets de la minoría en la discusión de la COP26.

En el cluster 3 aparecen críticas explícitas: “rats”, “weakness” y “lost”. En el cluster 4, aparecen palabras que asociamos con críticas hacia las políticas tomadas durante la pandemia del COVID-19: “lockdown”, “masks”, “vaccine” y “school” (en relación al cierre de escuelas durante la cuarentena). Además, vuelven a aparecer críticas hacia los participantes de la conferencia por utilizar aviones privados. Por ejemplo, a este cluster pertenece el tweet de @JamesMelville que narra: “*Ya sea con los aviones privados, las mascarillas o los pasaportes de vacunación, nuestros líderes políticos adoptan la postura hipócrita de ‘haz lo que decimos, pero no lo que hacemos’*”.

Por último, en el cluster 5 aparecen palabras relacionadas con el gobierno escocés, anfitrión de la conferencia, en el contexto de una nueva ola de contagios de COVID-19 [35]: se menciona a la Primera Ministra Sturgeon, y aparecen las palabras “health” y “nhs” (el servicio de salud escocés).

Haciendo ahora análisis de tópicos en los tweets de la mayoría, identificamos 4 clusters. Observamos que el 98% de los tweets pertenecen al cluster principal. En la figura 4.6 se muestran nubes de palabras para cada cluster.

Observamos que en el cluster principal (el cluster 0) aparecen las palabras “action”, “people”, “need”, “leaders”, “emissions” que relacionamos con la necesidad de tomar acción y la responsabilidad de los líderes políticos frente al problema del cambio climático. También destaca la palabra “auspol” que hace referencia a los políticos australianos involucrados en la COP26. No encontramos palabras de crítica,



**Figura 4.6:** Nubes de palabras asociadas a cada cluster identificado mediante el análisis de tópicos con BERT en los tweets de la mayoría en la discusión de la COP26.

sino más bien expresiones de preocupación.

En el cluster 1 aparecen claves referencias de crítica hacia “tory” haciendo referencia al partido conservador inglés liderado por el ex Primer Ministro Boris Johnson. Por último, en los 2 clusters restantes, que representan alrededor del 1% de los tweets, aparecen palabras que interpretamos como crítica por parte de escoceses hacia los líderes políticos ingleses por su postura frente al Brexit, con palabras (que representan hashtags) como “scotlandheldcaptive”, “scottishindependence” o “help”, “tyranny” y “uk”.

En general, concluimos que los tweets de la mayoría hacen referencia a la necesidad de tomar acción climática y la responsabilidad de los políticos en este tema. Además se observan críticas hacia el partido conservador inglés. Por otro lado, en la minoría se distinguen clusters con críticas bien definidas hacia los políticos involucrados en la COP26. También observamos un cluster exclusivamente relacionado con críticas hacia las políticas de salud pública tomadas durante la pandemia del COVID-19. Estudiar más profundamente la relación entre la pandemia y las posturas de los usuarios respecto al cambio climático es algo importante de investigar para trabajos futuros.

## 4.3. Redes de retweets

A lo largo del trabajo calculamos los scores de los usuarios y los influencers a partir del método de Latent Ideology, que tiene como input una matriz de adyacencia bipartita definida a partir de redes de retweets asociadas a cada una de las conferencias. En esta sección vamos a estudiar estas redes.

En particular nos enfocaremos en estudiar las interacciones de los usuarios con score definido dentro de estas redes. En la subsección 4.3.1, analizaremos la formación de echo chambers en la COP21 y en la COP26. En la sección 4.3.2 vamos a analizar estas redes de retweets en la capa de los influencers. Por último, en la sección 4.3.3, estudiamos como emergen comunas de interacción en la red de retweets y como se ubican los influencers de ambos polos en estas estructuras.

### 4.3.1. Cámaras de Eco

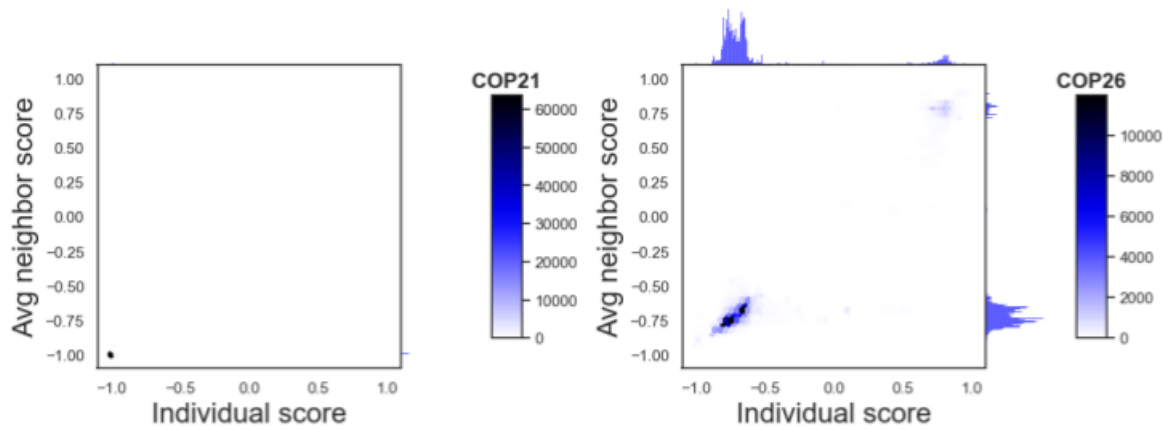
Las cámaras de eco (o echo chambers), se refieren a la situación en la cual las personas están expuestas principalmente a información y opiniones que confirman y refuerzan sus propias creencias y perspectivas, mientras se excluye o minimiza la exposición a información o puntos de vista diferentes [36, 37].

Para analizar la posible existencia de cámaras de eco en nuestros datos estudiamos la relación entre usuarios de la red (con LI definido), excluyendo del análisis a los influencers. Notar que no tiene sentido incluir a estos influencers en el análisis pues su score esta definido a partir de los scores de los usuarios que interactuaron con ellos.

Finalmente, siguiendo el enfoque de Cinelli et. al. [38] estudiamos la formación de cámaras de eco mirando si los primeros vecinos de cada usuario en las redes de retweets tienen la misma ideología climática (mismo LI). Para esto, calculamos el promedio del score de los primeros vecinos de cada nodo en la red y comparamos el score de los usuarios con el score promedio de sus vecinos.

Para la COP21, de los  $7,5 \times 10^4$  usuarios con scores, pudimos calcular el promedio del score de sus vecinos para  $6,5 \times 10^4$  usuarios, mientras que para la COP26, de los  $1,8 \times 10^5$  usuarios con scores, pudimos calcular el promedio del score de sus vecinos para  $1,5 \times 10^5$  usuarios. En la figura 4.7 se observan los scores de los usuarios en función del score de los primeros vecinos de cada usuario para las conferencias COP21 y COP26.

En el caso de la COP21, donde la presencia de influencers en la minoría es escasa, no se observa la formación de cámaras de eco entre los usuarios de dicho subgrupo. Sin embargo, en el subgrupo de la mayoría se aprecia que los usuarios tienden a



**Figura 4.7:** Score de los usuarios de las conferencias COP21 (izquierda) y COP26 (derecha) en función del promedio del score de sus primeros vecinos en la red de retweets.

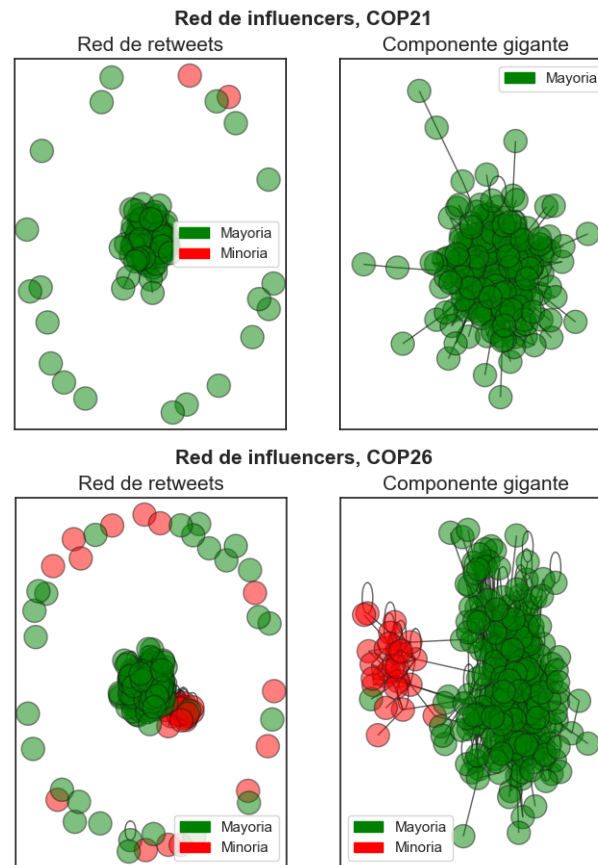
interactuar principalmente con aquellos que tienen un score similar.

En cambio, para la COP26, donde tanto la minoría como la mayoría cuentan con un gran número de usuarios, es más evidente la formación de cámaras de eco en ambos subgrupos. Se observa que los usuarios con score negativo tienden a interactuar principalmente con otros usuarios que tienen score negativo, al igual que ocurre con los usuarios con score positivo, quienes tienden a interactuar principalmente con usuarios de score similar.


### 4.3.2. Redes de retweets de influencers

Identificando las relaciones entre influencers en el análisis podemos visualizar las redes de influencers asociadas a ambas conferencias. Estas se observan en la figura 4.8.

Para la COP21, la red de  $m = 300$  influencers consta de 278 nodos interconectados, mientras que para la COP26 la red consta de 261 nodos interconectados. Se observa un alto grado de homofilia en la red asociada a la COP26. En concreto, la homofilia de la red, calculada a partir de la ecuación 3.11 presentada en la sección 3.4.2, tiene un valor de 0,94. Dado este alto valor, buscamos identificar cámaras de eco, pero esta vez sobre la capa de los influencers. Es decir, podemos calcular el promedio de los scores de los primeros vecinos de cada influencer y ver su distribución de scores en función de la distribución de los scores de sus vecinos. Esto se observa en la figura 4.9.



**Figura 4.8:** Red de retweets entre influencers para la COP21 (arriba) y para la COP26 (abajo). A la izquierda, la red de retweets, coloreada según el subgrupo al que pertenece el influencer: nodos verdes indican influencers de la mayoría y nodos rojos indican influencers de la minoría. A la derecha, la componente gigante de la red.



**Figura 4.9:** Score de los influencers de las conferencias COP21 (izquierda) y COP26 (derecha) en función del promedio del score de sus primeros vecinos en la red de retweets de influencers. Para una mejor visualización de los datos, ajustamos el rango de visualización del vector de scores (que va de -1 a 1), enfocándonos en los sectores donde los datos son distintos de 0.

Nuevamente, al igual que en la red de usuarios, en la red de influencers de la



COP21 observamos que influencers de la mayoría interactúan con influencers que pertenecen al mismo subgrupo. Los 2 influencers de la minoría, por otro lado, no interactúan con ningún otro influencer.

En la COP26 se observa el mismo comportamiento que lo visto en la red de usuarios: aparecen echo chambers en cada subgrupo. Concluimos que la aparición de cámaras de eco no es un fenómeno exclusivo de la red de usuarios sino que también se da entre los influencers.

### 4.3.3. Detección de comunas

En esta sección detectaremos comunas en las redes de las conferencias COP21 y COP26. Utilizaremos el algoritmo de Louvain que describimos en la sección 3.4.

Para la red asociada a la conferencia COP21 encontramos 72 comunas, mientras que para la red asociada a la conferencia COP26 encontramos 170 comunas.

Comuna	Cantidad de nodos	Score	Usuarios en discusión [%]	Descripción
0	18549	-0,99	18	-
1	17511	-0,99	37	-
2	14913	-0,99	51	-
3	14697	-0,99	66	-
4	6267	-0,99	73	-
5	5966	-0,99	79	-
<b>6</b>	<b>4160</b>	<b>-0,99</b>	<b>83</b>	-
7	3732	-0,99	86	-
8	2647	-0,99	89	-
9	2278	-0,28	90	Minoría
10	2244	-0,99	92	-
11	2099	-0,99	93	-
12	2027	-0,99	95	-
13	1910	-0,99	97	-
14	1508	-0,99	98	-
15	597	-0,99	98	Pakistán

**Tabla 4.1:** Cantidad de nodos, score y porcentaje acumulado de usuarios de la discusión captados en cada comuna, para la red asociada a la COP21. Se resalta la comuna en la que aparecen el 80% de los usuarios de la discusión.

En el caso de la COP21, el 70% de los influencers de la discusión se encuentran en las cuatro primeras comunas con mayor cantidad de nodos y el 83% de los

usuarios de la discusión se encuentran en las primeras 6 comunas; aunque también hay influencers presentes hasta la comuna número 18 en orden descendente según la cantidad de nodos por comuna y usuarios hasta la comuna en la posición 50. El subgrupo de influencers de Pakistán, que previamente habíamos identificado como un grupo apartado del resto debido a consideraciones geográficas, pertenece a la comuna ubicada en la decimoquinta posición en términos de cantidad de nodos por comuna. Por último, el subgrupo que habíamos identificado como la “minoría”, compuesto por los influencers @BjornLomborg y @JunkScience, se encuentra en la novena posición (contando desde el 0). Cabe mencionar que esta comuna no es exclusiva de la minoría, sino que también la conforman usuarios de la mayoría. En la tabla 4.1 se muestra la distribución en tamaño de las comunas para la COP21.

Comuna	Cantidad de nodos	Score	Usuarios en discusión [%]	Descripción
0	61345	-0,72	15	-
1	53216	-0,72	25	-
2	42133	-0,64	40	-
3	40041	0,61	52	Minoría
4	36109	-0,69	62	-
5	24121	-0,60	67	-
6	21367	-0,73	68	Corea
7	20331	-0,6	69	India
8	14464	-0,81	73	-
9	9682	-0,60	76	-
10	8051	-0,60	77	-
11	4177	-0,48	77	-
12	3515	-0,70	78	-
13	1338	-0,73	78	-
14	1331	-0,59	78	-
15	1321	-0,72	78	-

**Tabla 4.2:** Cantidad de nodos, score y porcentaje acumulado de usuarios de la discusión captados en cada comuna, para la red asociada a la COP26.

En el caso de la COP26, el 50% de los influencers se encuentran en las cinco primeras comunas con mayor cantidad de nodos, y el 80% de los usuarios se halla en las primeras 20 comunas, aunque hay influencers presentes hasta la comuna número 20 en orden descendente según la cantidad de nodos por comuna y usuarios presentes hasta la comuna 100. El subgrupo de influencers asociado al grupo musical coreano “BlackPink”, que habíamos excluido de nuestra discusión, se encuentra en la posición

6, mientras que el subgrupo de políticos de la India, también excluido de nuestra discusión (pasos 1 y 3 del proceso iterativo para la COP26 de la sección 6.2), se encuentra en la posición 7 en término de cantidad de nodos por comuna. El subgrupo que previamente identificamos como la “minoría”, conformado por 41 influencers, se encuentra en la posición 3 en la distribución de nodos por comunas (contando desde el 0). En la tabla 4.2 se muestra la distribución en tamaño de las comunas para la COP26.

También podemos analizar la distribución de scores de cada comuna, donde el score de cada comuna es definido como el promedio del score de los usuarios que pertenecen a cada comuna. Este score se observa en la tercer columna de las tablas 4.1 y 4.2.

Confirmamos la presencia de la minoría en la comuna 9 de la COP21 y en la comuna 3 de la COP26, pues el score de dichas comunas es positivo (COP26) o se aleja considerablemente en score del resto de las comunas (COP21). En el caso de la discusión de la COP26, al considerar las 6 primeras comunas, podemos obtener la distribución que obtuvimos al finalizar el proceso iterativo de eliminación de influencers seleccionados. En cambio, para la COP21, deberíamos considerar las primeras 9 comunas. Es evidente que los subgrupos que hemos eliminado corresponden a comunas periféricas de la red y no a las comunas principales con mayor cantidad de nodos. Sin embargo, no podemos establecer un límite para la cantidad de comunas a considerar de manera que podamos distinguir al subgrupo de la minoría y dejemos de lado a los subgrupos que hemos eliminado selectivamente. A menos que tengamos conocimiento previo sobre qué grupos deseamos excluir de la discusión, llegamos a la conclusión de que un filtrado basado únicamente en la selección de las  $N$  comunas principales de la red no es criterio suficiente para captar una discusión ambientalista dentro del debate, ya que no podemos determinar el valor de  $N$ .

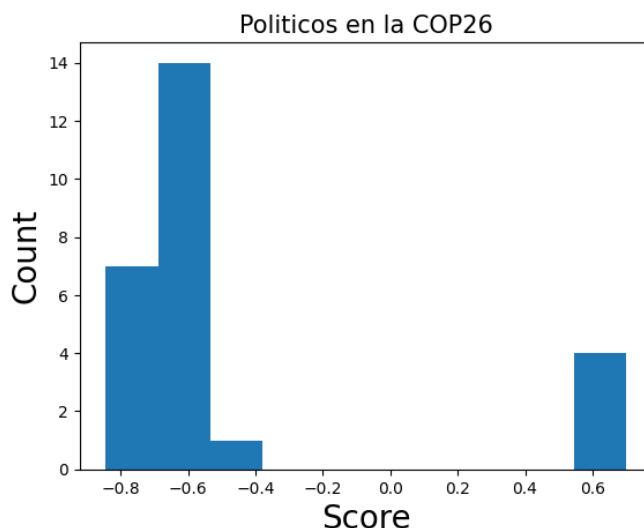
## 4.4. Dimensión Política

Como mencionamos en la sección 2.2, disponemos de un dataset con IDs de Twitter de cuentas asociadas a políticos. Debido a la gran cantidad de datos que tenemos para la conferencia de la COP26 y debido a que el grupo minoritario esta compuesto por muchos mas influencers que en la COP21 (recordemos que en la COP21 teníamos solo 2 influencers en la minoría mientras que en la COP26 teníamos 41 influencers), procedemos a trabajar sobre la base de datos asociada a la COP26.

Planteamos la hipótesis de que la filiación política de los usuarios está correlacionada con el score obtenido en el debate climático. Por lo tanto, esperamos que

el subgrupo que identificamos como “la minoría” tenga afinidad con algún sector político, y que lo mismo pasaría con el subgrupo identificado como “la mayoría”.

Para comprobar esto, primero identificamos a los políticos que pertenecen a la red de retweets de la COP26. Dentro de esta red, encontramos 508 políticos. De estos 508, solo 26 pasaron la etapa de filtrado descrita en la sección 6.2 y son considerados como influencers en esta red. La distribución de scores de estos 26 políticos en la discusión ambientalista identificada se muestra a continuación en la figura 4.10.



**Figura 4.10:** Distribución de scores de los 26 políticos identificados en la discusión ambientalista dentro de la COP26.

Observamos que 4 políticos pertenecen a la minoría de la distribución y 22 pertenecen al subgrupo mayoritario. Dentro de los “políticos de la mayoría” identificamos 18 políticos británicos, 2 políticos canadienses y 2 políticos australianos. Haciendo una inspección manual sobre estos 18 políticos británicos, observamos que 2 de ellos pertenecen al partido conservador británico, 2 pertenecen al GreenParty británico y el resto pertenecen al Partido Laborista. La abundante presencia de partidos de centro-izquierda como el Partido Laborista o el GreenParty en la mayoría política se distingue de los partidos políticos presentes en la minoría, que tienen una postura política de derecha o centro-derecha.

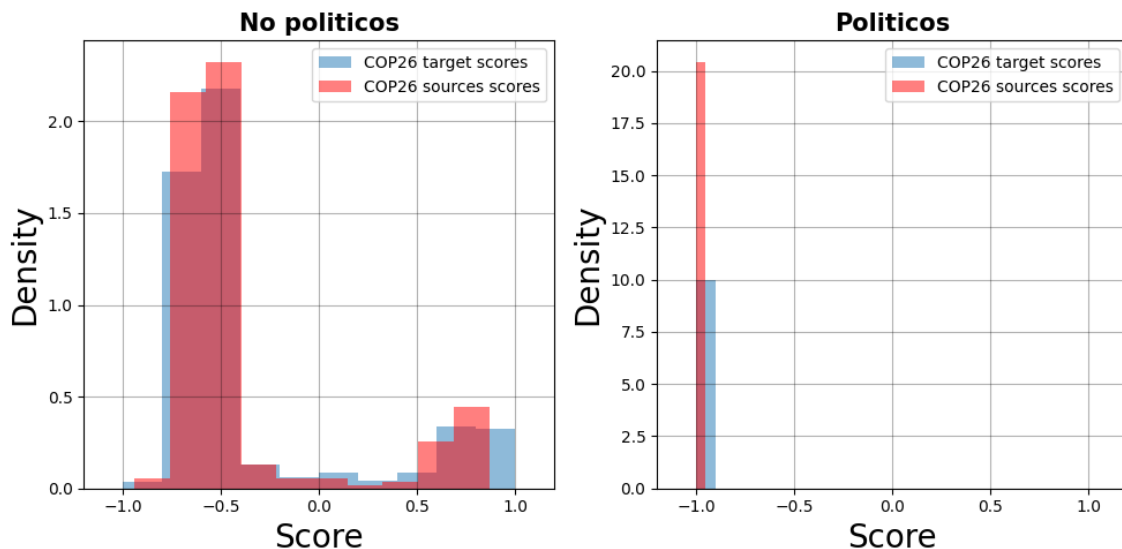
Los políticos de la minoría son Steve Baker, Martin Daubney, Nigel Farage y Richard Tice. Podemos establecer una relación entre estos políticos pues los 4 abogaron por la salida de Gran Bretaña de la Unión Europea, movimiento conocido como el Brexit. Steve Baker, miembro del partido conservador británico, fue presidente del ERG, un grupo de diputados conservadores a favor del Brexit, y el resto de los tres políticos forman parte del Partido de la Independencia del Reino Unido (UKIP) que aboga por el Brexit [39].

Es clara la tendencia de ambos subgrupos detectados previamente: los usuarios del subgrupo de la mayoría en el debate ambientalista tienden a establecer interacciones con políticos de izquierda o centro-izquierda y los usuarios del subgrupo de la minoría tienden a establecer interacciones con políticos de derecha o centro-derecha.

A fin de indagar un poco más en la tendencia mencionada construiremos por un lado una red exclusiva de políticos y usuarios, y, por otro lado, la clásica red de usuarios-influencers con la que hemos estado trabajando hasta ahora, con la excepción de que excluirémos de la red a los 26 políticos que consideramos como influencers. La intención detrás de esto es tener una red exclusiva de políticos y otra red exclusiva de usuarios no políticos.

El siguiente paso es aplicar el método de Latent Ideology en estas redes. En el caso de la red de no políticos, consideramos, como antes  $m = 300 - 26 = 274$  influencers y  $n \geq 2$ . Por otro lado, en la red de políticos, como solo tenemos 26 políticos, no impondremos restricciones al parámetro  $m$ , pero pedimos, nuevamente, que los usuarios hayan interactuado con al menos 2 políticos ( $n \geq 2$ ).

El output del método es una lista de scores. Al score calculado en la red política, lo llamaremos “score político” y al score calculado en la red no política lo llamaremos “score ambientalista”. Las distribuciones de scores para usuarios e influencers, para ambas redes, se observan en la figura 4.11.



**Figura 4.11:** Distribuciones de scores para usuarios e influencers dentro de la discusión de la COP26. A la izquierda: distribución de scores para la red usuarios-influencers no-políticos. A la derecha: distribución de scores para la red de políticos como influencers.

En la distribución de scores de usuarios e influencers asociados a la red de no-políticos, el 100% de los influencers con score mayor a 0 pertenece al subgrupo de

la minoría que detectamos previamente. Si bien la distribución cambia al excluir de la discusión a estos 26 influencers, se conserva la pertenencia a estos subgrupos.

En la distribución de los scores de los usuarios asociados a la red de políticos como influencers (representada en el gráfico de la derecha de la figura 4.11), observamos una distribución unimodal ( $D = 0,05$ ,  $p = 0,98$ ), por lo que no es posible estudiar polarización alguna.

Dado que no se encontró polarización ideológica política en el debate de la COP26, no pudimos asignar “scores políticos” a los usuarios y, por lo tanto, no pudimos estudiar (mediante este enfoque) si los subgrupos identificados en la sección 4.1 tienen alguna tendencia específica hacia alguna afiliación política en particular. Se estudió también la posibilidad de no considerar los 26 políticos identificados, sino de estudiar la distribución de scores de todos los usuarios que interactuaron con los 18 políticos británicos. Pero, nuevamente, obtuvimos una distribución de scores unimodal. Concluimos que no es posible discernir una discusión política dentro del debate de la COP26. Queda como trabajo a futuro el estudio de esta discusión en particular en este contexto.

## 5. Conclusiones

En esta tesis investigamos las redes de retweets asociadas a las conferencias anuales sobre el cambio climático COP21 y COP26 centrándonos en la posible polarización del debate. En estas redes, los nodos representan usuarios de la plataforma involucrados en las discusiones de las COP, y los enlaces (o links) entre nodos corresponden a interacciones dirigidas en forma de retweets.

Las redes fueron construidas a partir de una base de datos de tweets y retweets recopilados en el periodo de un año (6 meses antes y 6 meses después de comenzadas las conferencias) que contienen las keywords COP21 y COP26, respectivamente. En la sección 4.1 estudiamos el uso de estas keywords a lo largo del tiempo

Observamos que las conferencias ganan relevancia en Twitter unos días antes de su inicio y durante los días posteriores a su finalización. Este patrón coincide con los tiempos de vida media típicos de este tipo de eventos [32].

Notamos que la conferencia COP26 fue mucho mas masiva en términos de cantidad de publicaciones y retweets que la COP21. Además, notamos que al final de la COP21, cuando se firmó el Acuerdo de París, hubo un pico en la cantidad de publicaciones/retweets relacionados con el debate, a diferencia del final de la COP26 con la firma del Pacto de Glasgow. Atribuimos esta diferencia entre los tratados a la ambición de las propuestas: el Acuerdo de París presentaba propuestas económicas mucho más ambiciosas que el Pacto de Glasgow.

Dadas estas redes de retweets, para poder identificar polarización entre usuarios enfocamos el trabajo hacia el estudio de un método en particular: el Latent Ideology (LI). Este es un método propuesto por Barberá [16] en el 2014 pero que esta basado en el concepto de "Latent Space Models" introducido por Hoff [17] en 2002. En esta tesis implementamos el enfoque de Latent Ideology con Correspondence Analysis (CA), presentado por Barberá en 2015 [18] a una red bipartita de usuarios e influencers.

Un resultado importante del análisis llevado a cabo al implementar este método es que para centrar el estudio en un tópico o debate en particular es muy importante el filtrado de influencers específicos. Dado que el método de LI asigna scores a

---

usuarios en función de su interacción con los influencers, puede suceder que en la distribución de scores se distingan subgrupos de usuarios alejados entre si. Uno estaría motivado de pensar que el método separa grupos con ideologías distintas, pero la realidad es que la separación en subgrupos puede darse por muchos otros factores. A lo largo del trabajo distinguimos subgrupos de usuarios que se alejaban en score del resto de los usuarios por cuestiones geográficas y culturales. Por ejemplo, para la COP21 encontramos un subgrupo de usuarios que interactuaban exclusivamente con políticos de Pakistán, por lo que se alejaban en score del resto de los usuarios por razones puramente geográficas. Este tipo de comportamientos también se observó con la COP26 y con el dataset de políticos de la sección 4.4.

Mediante la aplicación del método de LI logramos identificar discusiones polarizadas dentro de los debates de las COP21 y COP26. Encontramos dos subgrupos distintos: uno con una postura a favor de la conferencia y otro con una postura crítica hacia la conferencia.

En relación al debate de la COP21, identificamos solo 2 influencers en el subgrupo que denominamos como “la minoría”. La presencia de estos 2 individuos, descritos en la sección 4.2.2 se condice con los estudios de Baronchelli et. al. en [1]. En este subgrupo, notamos un claro perfil de crítica hacia las posturas mainstream sobre el cambio climático. En cuanto al debate de la COP26, encontramos 41 influencers en la minoría. Dentro de este subgrupo, detectamos a 5 individuos con perspectivas alejadas de las posturas predominantes sobre el cambio climático.

En la sección 4.2.2, realizamos un análisis detallado de los tweets asociados a ambos subgrupos utilizando el análisis de tópicos con BERTopic. Observamos que de los 6 clusters identificados del grupo minoritario, 5 de ellos están relacionados con tópicos que tienen una connotación crítica hacia eventos de la conferencia. Por ejemplo, asociamos el cluster 2 directamente con el discurso recurrente en los tweets que critican la utilización de aviones privados por parte de los políticos para asistir a la conferencia. Además, relacionamos el cluster 1 con el suceso, que muchos usuarios consideran de hipócrita, asociado a la fotografía entre la primer ministra escocesa y anfitriona de la COP26, Nicola Sturgeon, y la activista climática Greta Thunberg. Curiosamente, uno de los clusters está completamente relacionado con la pandemia del COVID-19. Como mencionamos en la sección 1, la conferencia se pospuso un año debido a la pandemia y durante la conferencia, la pandemia seguía vigente. El hecho de que el debate sobre la pandemia ocurriera en el contexto de un debate climático no es casualidad, pues también se observó en [1] al trabajar con el mismo objeto de estudio. Al analizar en detalle los tweets asociados a este cluster, concluimos que cuando se habla del COVID-19, se lo hace con una connotación crítica hacia las



---

políticas sociales y sanitarias adoptadas, como la cuarentena, el cierre de escuelas y el uso de tapabocas.

Con respecto a los tweets del grupo mayoritario, encontramos 4 clusters, en donde el cluster principal (cluster 0) contiene el 98% de los tweets de este subgrupo. En este cluster pudimos identificar claras referencias hacia la necesidad de tomar acción climática urgente. Por otro lado, en el cluster 1 identificamos críticas hacia el partido conservador británico que aboga por el Brexit, y en el resto de los clusters identificamos palabras asociadas a sectores escoceses que promueven la independencia de Escocia del Reino Unido dadas las tensiones respecto al Brexit. La relación entre el debate climático y el Brexit es un tema que merece ser estudiado en detalle y lo proponemos como una investigación a futuro.

También, en la sección 4.3.1 estudiamos la posible formación de cámaras de eco en el debate. Para esto, graficamos (figura 4.7) el score de los usuarios en función del score promedio de sus primeros vecinos en la red de retweets. Observamos la aparición de cámaras de eco en estas redes. Las cámaras de eco no solo fueron halladas en la red de usuarios sino en la red de influencers. Esto se puede ver en la sección 4.3.2.

Para finalizar, estudiamos la existencia de una posible relación entre el score que definimos como “score climático” y la filiación política de los usuarios para la conferencia COP26. Para esto, a partir de una base de datos de políticos en Twitter (ver sección 2.2), pudimos identificar a los personajes políticos involucrados en estas redes: encontramos que 26 cuentas de influencers estaban asociadas a cuentas políticas. Tras una inspección visual de estas cuentas (asociadas a estos políticos involucrados), concluimos que el subgrupo que consideramos como la minoría en la discusión climática presenta una tendencia a interactuar con políticos de centro-derecha y que el subgrupo que consideramos como la mayoría en esta misma discusión presenta una tendencia a interactuar con políticos de centro-izquierda. Sin embargo, tras plantear un enfoque en donde recalculamos el LI dos veces, primero sobre una red de usuarios-no políticos y luego sobre una red exclusiva de usuarios-políticos (considerando los 26 políticos identificados), no encontramos polarización ideológica en la red de usuarios-políticos.

Por último, cabe aclarar que creamos una librería de Python para facilitar a los usuarios la aplicación de este método. Los detalles de esta librería se introducen en la sección 6.4 o directamente se pueden ver en mi repositorio de Github: [https://github.com/fedemoss/latent\\_ideology](https://github.com/fedemoss/latent_ideology).

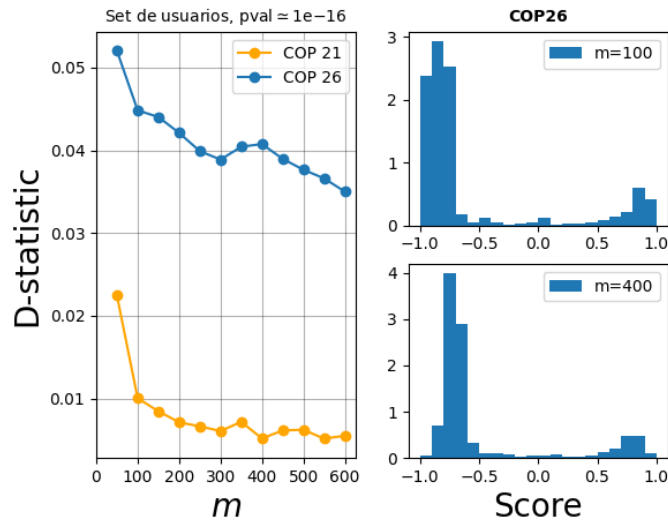
## 6. Apéndice

### 6.1. Barrido en parámetros del modelo

Queremos evaluar el impacto de los parámetros  $m$ ,  $n$  y  $k$  que detallamos en la sección 3.1.3 en las distribuciones de scores que mostramos en la sección 4.2.1. Para ello, estudiamos la variación de estos parámetros en función de la multimodalidad de las distribuciones. Para lograrlo, luego de aplicar el filtrado de usuarios específicos, como se detalla en la sección 6.2, se procedió a calcular el valor de la D-estadística utilizando el test de Hartigan.

#### 6.1.1. Variación de $m$

Consideremos los  $m$  influencers mas retweeteados por usuarios diferentes; es decir, consideremos los  $m$  nodos con mayor centralidad de grado de entrada en nuestra red de retweets.



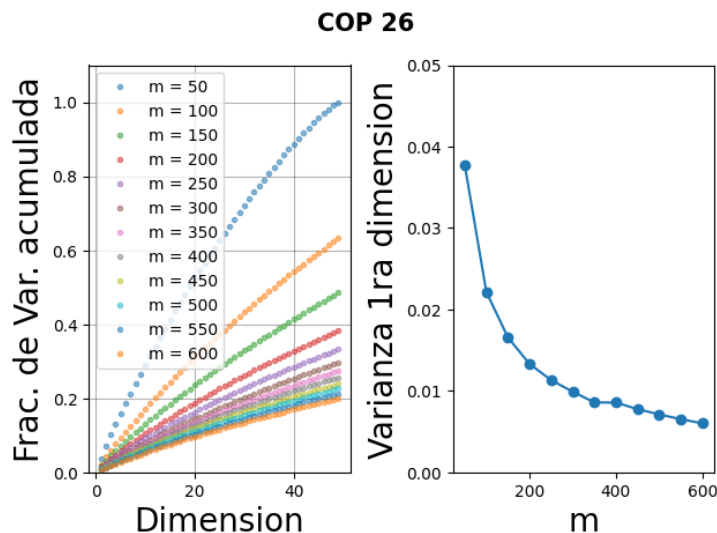
**Figura 6.1:** A la izquierda, variación del parámetro  $m$ , definido como “cantidad de influencers en la red” en función de la D-estadística del dip test de Hartigan; para la distribución de usuarios de la COP21 y la COP26. A la derecha, distribuciones asociadas a la elección de parámetros  $m = 100$  y  $m = 400$  para la COP26.

Comenzamos mirando la variación de la D-estadística en función del  $m$  para la distribución de usuarios de la COP21 y la COP26. Esto se observa en la figura 6.1.

Se puede observar que la discusión en torno a la COP26 es más multimodal en comparación con la COP21. En la sección 4.2.1 se detalla este análisis con mayor profundidad.

Además, se aprecia que a partir de  $m = 200$ , la curva correspondiente a la COP21 se mantiene estable. En contraste, para la COP26 no se observa estabilidad en la curva, aunque observando los gráficos para los casos  $m = 100$  y  $m = 400$ , se observa que ambas distribuciones son notablemente bimodales.

Podemos evaluar la cantidad de información perdida al variar el parámetro  $m$ . Para esto, en la figura 6.2 se muestra la fracción de varianza acumulada en función de la dimensión de la reducción utilizando SVD, así como la fracción de varianza en la primera dimensión en función de  $m$  para la discusión de la COP26.

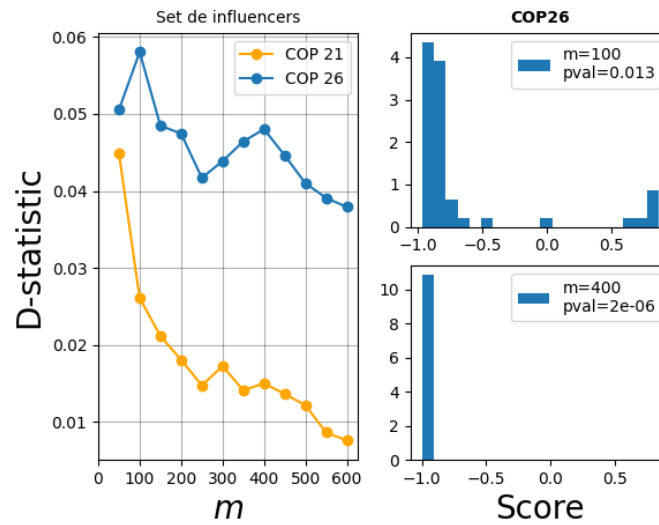


**Figura 6.2:** A la izquierda: Fracción de varianza acumulada en función de la dimensión tras la descomposición en SVD truncado para la COP26. A la derecha: Fracción de varianza en la primera dimensión en función del número  $m$  de sources considerados.

Aunque al truncar a la primera dimensión solo conservamos aproximadamente el 1% de la varianza de los datos, comprobamos que esta cantidad es suficiente para capturar la polarización presente en los datos (ver distribuciones de scores, sección 4.2.1). Por otro lado, a medida que aumenta el valor de  $m$ , disponemos de más información y, como era de esperarse, perdemos más información al truncar a una sola dimensión.


Siguiendo la metodología de [1], se considera que el valor de  $m = 300$  es adecuado para las distribuciones de ambas conferencias, ya que logra un balance entre estabilidad y poca pérdida de información en ambas distribuciones.

También podemos estudiar la variación de la D-estadística con el parámetro  $m$  en la distribución de scores de los influencers. Esto se observa en la figura 6.3.



**Figura 6.3:** A la izquierda, variación del parámetro  $m$  en función de la D-estadística del dip test de Hartigan para la distribución de influencers de la COP21 y la COP26. A la derecha, distribuciones asociadas a la elección de parámetros  $m = 100$  y  $m = 400$  para la COP26.

Una vez más, se puede observar que la discusión sobre la COP26 es más multimodal en comparación con la COP21. Además, se puede notar una tendencia decreciente en ambas curvas a medida que aumenta el valor de  $m$ .



**Figura 6.4:** Variación del parámetro  $m$  en función del p-valor asociado al dip test de Hartigan, para la COP21 y para la COP26. Si el p-valor es mayor que el umbral 0,01, no podemos rechazar la hipótesis de unimodalidad.

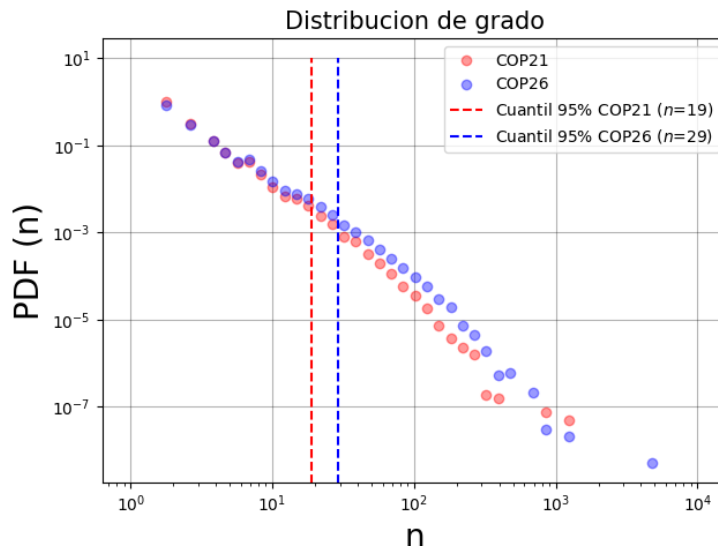
En la COP26, para valores pequeños de  $m$ , donde el conjunto de influencers es

pequeño, no podemos rechazar la hipótesis de unimodalidad, ya que el p-valor es mayor a 0.01, el umbral que habíamos establecido. Podemos ver mas en detalle como varia el p-valor con  $m$  en la figura 6.4.

Se puede observar que para la COP21, el p-valor es mayor al umbral para todo  $m$ . Por otro lado, para la COP26, a partir de  $m = 150$ , podemos rechazar la hipótesis de unimodalidad.

### 6.1.2. Variación de $n$

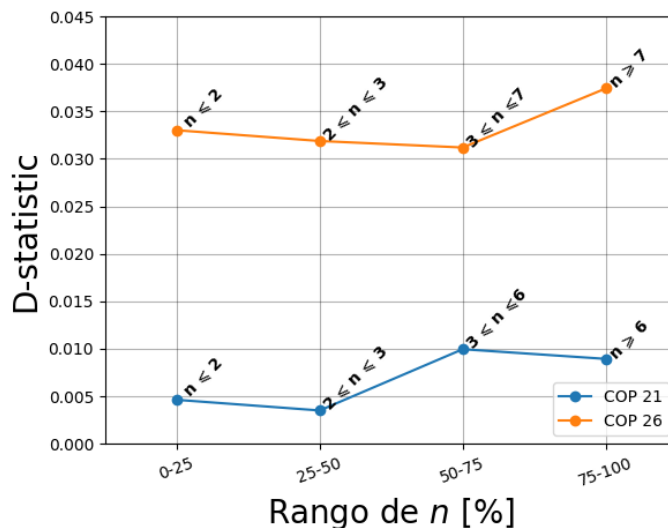
Sea  $n$  la cantidad de influencers retweeteados por cada usuario; es decir, el grado de salida de cada nodo. Comencemos mirando como es la distribución de grado de la red. Esto se observa en la figura 6.5.



**Figura 6.5:** Distribución de grado de las redes de retweets asociadas a la COP21 y a la COP26.

Observamos que esto sigue una distribución libre de escala, en donde pocos usuarios retweetean mucho y muchos usuarios retweetean poco. El 95 % de los usuarios tienen  $n < 19$  para la COP21 y  $n < 29$  para la COP26 y el 50 % tiene  $n < 3$  para la COP21 y  $n < 4$  para la COP26.

Adicionalmente, podemos seguir un enfoque análogo al utilizado para el parámetro  $m$  y estudiar la relación entre la variación del parámetro  $n$  y los valores de la D-estadística del dip test de Hartigan para las distribuciones asociadas. Para ello, estudiamos como es la distribución de scores en función de rangos de  $n$ . En donde definimos como rango de  $n$  a los valores de  $n$  que pertenecen a los intervalos de data [0 %, 25 %], [25 %, 50 %], [50 %, 75 %] y [75 %, 100 %]. Esto se observa en la figura 6.6.



**Figura 6.6:** Variación del rango del parámetro  $n$  en función de la D-estadística del dip test de Hartigan, para la distribución de influencers de la COP21 y la COP26

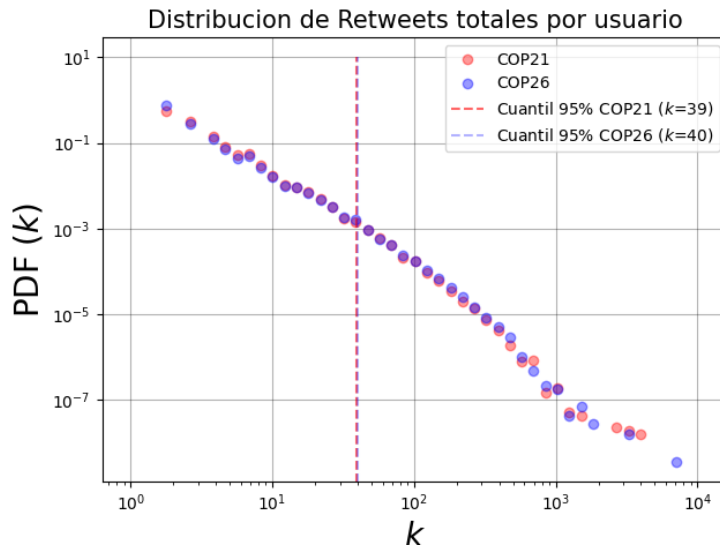
Al considerar usuarios que tienen una cantidad limitada de retweets a influencers distintos dentro de un rango determinado, observamos que la D-estadística no presenta una variación significativa. Por lo tanto, concluimos que, dada esta definición de rango, limitar nuestra atención a los usuarios que pertenecen a alguno de estos rangos no tiene un impacto significativo en la distribución final de scores. Entonces, para minimizar la pérdida de información y obtener una idea del espectro de retweets de cada usuario, adoptaremos el enfoque propuesto por [1] y estableceremos  $n \geq 2$  como parámetro del modelo.

### 6.1.3. Variación de $k$

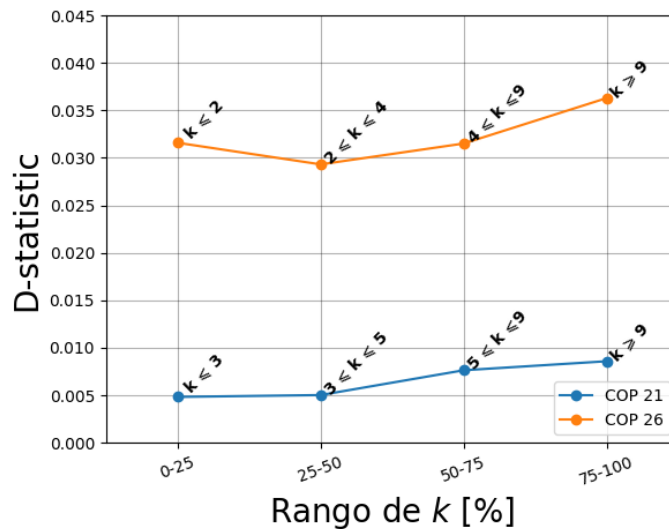
En la sección anterior, analizamos la variación en el espectro de retweets a influencers distintos dentro de la red, es decir, estudiamos la distribución de grado de los usuarios de la red. Como los usuarios pueden retweetear varias veces a un mismo influencer, podemos estudiar la distribución en la cantidad total de retweets realizados por cada usuario. A esta cantidad total de retweets de cada usuario la llamamos  $k$ . En la figura 6.7, se puede observar la distribución de  $k$

Se observa que el 95 % de los datos tiene  $k < 39$  retweets para la COP21 y  $k < 40$  retweets para la COP26 y que el 50 % de los datos tiene  $k < 4$  retweets para ambas conferencias.

Siguiendo un enfoque análogo a lo que hicimos con el parámetro  $n$ , podemos estudiar los rangos de  $k$  en función de la D-estadística. Nuevamente, definimos el rango de  $k$  a partir de los cuantiles 25 %, 50 % y 75 %. Esto se observa en la figura 6.8.



**Figura 6.7:** Distribución de links totales ( $k$ ) entre usuarios de las redes de retweets asociadas a la COP21 y a la COP26.



**Figura 6.8:** Variación del rango del parámetro  $k$  en función de la D-estadística del dip test de Hartigan; para la distribución de influencers de la COP21 y la COP26

Análogamente a lo visto con el parámetro  $n$ , al considerar usuarios que tienen una cantidad limitada de retweets totales dentro de un rango determinado, observamos que la D-estadística no presenta una variación significativa. Dicho esto, no impondremos restricciones sobre  $k$  para el análisis de la distribución de scores.

## 6.2. Filtrado de usuarios

Como se ha señalado en la sección 2.1, únicamente se incluirán en el análisis a usuarios asociados a cuentas activas y no eliminadas. Además, con el objetivo de evitar la inclusión de cuentas automatizadas, se considerarán únicamente aquellos tweets escritos en inglés y publicados a través de dispositivos móviles (Android y IOS).

En adición a las restricciones mencionadas, aplicaremos un filtro adicional: el filtrado de usuarios seleccionados. Para poder analizar exclusivamente una discusión ambientalista en el debate de las COP, trataremos de aislarla del resto de las posibles discusiones mediante la selección específica de usuarios.

Tras aplicar el método de LI a las matrices de adyacencia de la COP21 y la COP26, encontraremos que la distribución de scores obtenida separa a los usuarios en discusiones no ambientalistas que ocurren dentro del contexto de la COP. Lo que haremos es identificar a estas discusiones y al conjunto de usuarios que las conforman, para luego filtrar a aquellos usuarios que no pertenecen a la discusión de interés. Este es un proceso iterativo, ya que deberemos filtrar varios grupos de usuarios hasta alcanzar la discusión que nos concierne.

La metodología utilizada para la detección de discusiones climáticas es similar para ambas conferencias (COP21 y COP26). Sin embargo, debido a que los procesos iterativos no tienen la misma cantidad de pasos para ambas conferencias, separaremos los procedimientos en dos secciones, cada una asociada a una conferencia en particular.

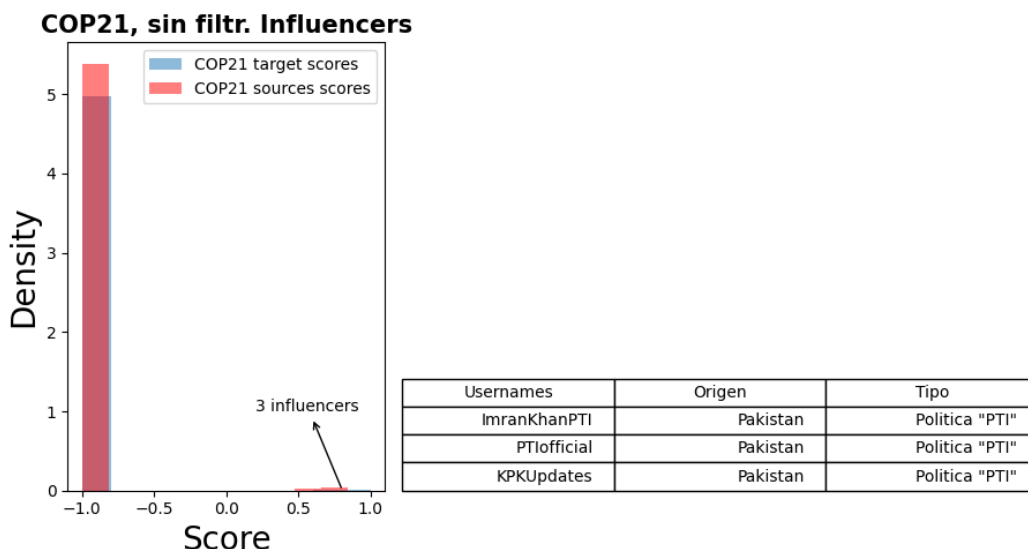
### 6.2.1. Filtrado iterativo de usuarios de la COP21

Comencemos estudiando la distribución de scores sin seleccionar a priori ningún conjunto de usuarios. Esta distribución se observa en la figura 6.9.

Notar que en la distribución a la izquierda de la figura 6.9 se distinguen dos grupos de influencers. El grupo mayoritario, con score cercano a  $-1$ , se separa completamente del otro grupo con score cercano a  $1$ . Este último, conformado por solo 3 influencers, será denominado como la “minoría” en esta distribución. En la tabla de la derecha de la figura se presenta una descripción detallada de este grupo.


La minoría en este caso esta compuesta por 3 usuarios Pakistaníes, relacionados entre si por formar parte del grupo político pakistaní Tehreek-e-Insaf (PTI). El PTI es un partido político de Pakistán fundado en 1996 por Imran Khan [40], perteneciente a este trío minoritario bajo el username “ImranKhanPTI”.





**Figura 6.9:** A la izquierda, distribución de scores de usuarios e influencers para la COP21. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

La separación completa de un grupo de 3 influencers del resto de los otros influencers indica que existe un subgrupo de usuarios dentro de nuestra base de datos que interactúa exclusivamente con estos 3 influencers pero que no con los demás. Además, que estos 3 influencers pertenezcan a un mismo país da indicios de un sesgo geográfico. Para comprobar esto, en la figura 6.10 se observa la distribución de países de origen de la “mayoría” en esta distribución.



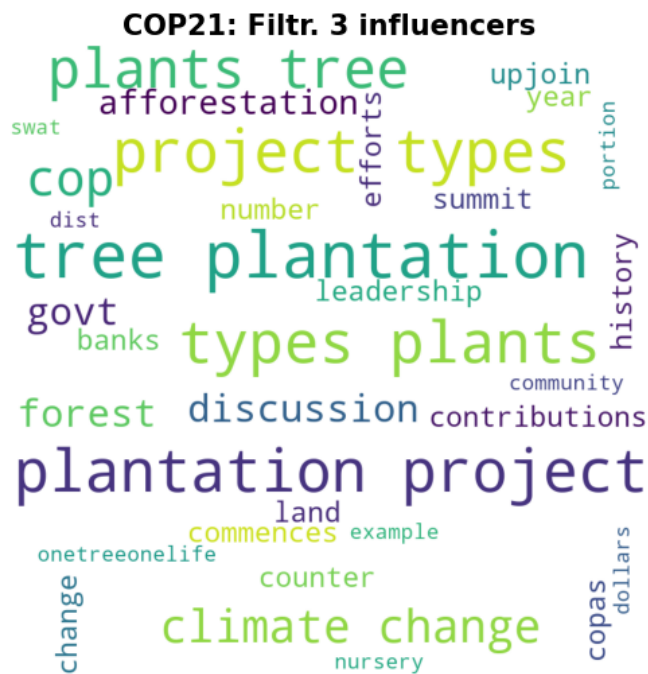
**Figura 6.10:** Distribución de países de origen de los influencers con score < 0 (“mayoría”) en la distribución de scores de influencers de la COP21 de la figura 6.9.

Es importante mencionar que se pudo determinar el país de origen de solo el

51 % de los influencers pertenecientes a la mayoría. No se pudo obtener información geográfica del resto de los influencers pues el atributo que indica la ubicación de los usuarios en Twitter es opcional y abierta, y no todos los usuarios optan por compartir esta información públicamente.

La distribución de países de la mayoría parcial, como se muestra en la figura 6.10, indica una clara tendencia de que los usuarios pertenecen principalmente a Estados Unidos, Reino Unido y Francia. Esta tendencia es comprensible, ya que estamos filtrando tweets exclusivamente en inglés y la conferencia tuvo lugar en Francia.

Adicionalmente, realizamos un análisis de los tweets de los tres influencers pertenecientes a la minoría para entender por qué están relacionados con la discusión de la COP21. En la figura 6.11 se muestra una nube de palabras de los tweets de este subgrupo.



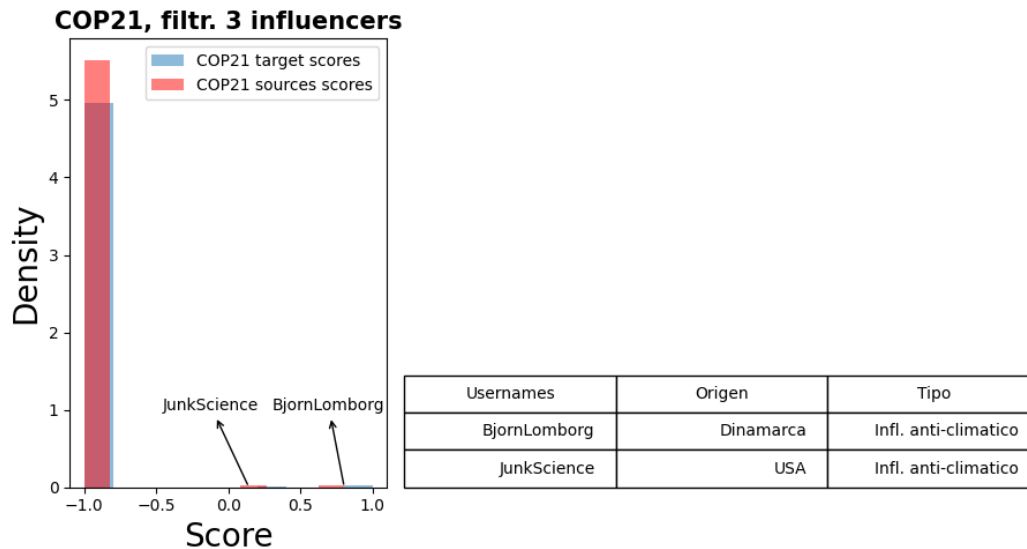
**Figura 6.11:** Nube de palabras de los tweets de los influencers con score  $> 0$  en la distribución de scores de la figura 6.9.

Observamos una connotación climática en los tweets del grupo minoritario, principalmente relacionada con la “plantación de árboles” como una medida para preservar el medio ambiente. Esta asociación coincide temporalmente y tiene una connotación política directa con el PTI, ya que se relaciona con el proyecto “Billion Tree Tsunami” [41]. Dicho proyecto tuvo como objetivo plantar mil millones de árboles en Pakistán para combatir la deforestación y el cambio climático.

Dado que la contabilización de influencers de Pakistán es nula en la distribución de países parcial de la mayoría y, dado que los tweets de estos influencers están

relacionados con un proyecto político en particular, podemos concluir que el surgimiento de este grupo minoritario es un sesgo geográfico que nada tiene que ver con la discusión ambientalista alrededor de la conferencia COP.

A continuación, procedemos a eliminar a estos tres influencers y a examinar cómo cambia la distribución de scores. La nueva distribución se puede observar en la figura 6.12.




**Figura 6.12:** A la izquierda, distribución de scores de usuarios e influencers tras la remoción de un subgrupo sesgado geográficamente compuesto por 3 influencers, para la COP21. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

Nuevamente, distinguimos un subgrupo minoritario de influencers con score mayor a 0. Analizando los tweets de estas personas, podemos identificar claramente un posición anti-ambientalista dentro de la discusión de la COP21.

La minoría de la COP21 tiene dos influencers: @BjornLomborg y @JunkScience. Estas personas tienen un claro enfoque climático y se identifican a sí mismas como por fuera del discurso mainstream sobre el clima. Describiremos en detalle a estos individuos en la sección 4.2.2.

Podemos continuar con el proceso iterativo, remover a estos dos individuos (@BjornLomborg y @JunkScience) de la discusión y volver a aplicar el método. En la figura 6.13 se observa la nueva distribución de scores.



**Figura 6.13:** A la izquierda, distribución de scores de usuarios e influencers tras la remoción de 5 influencers, para la COP21. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

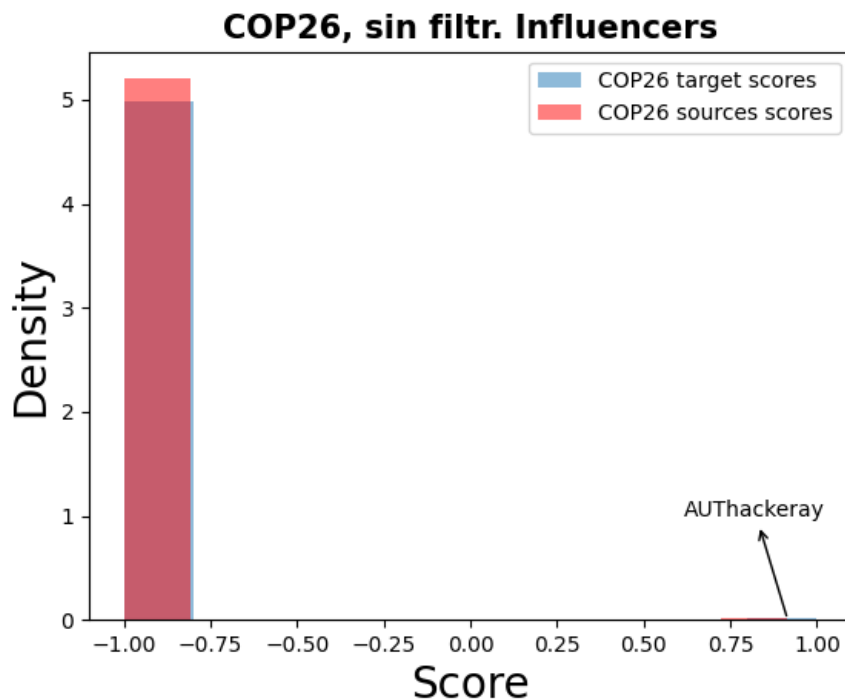
Observamos que dentro de la mayoría en la discusión climática, aparece un subgrupo de influencers procedentes en su mayoría de la India (salvo 2 cuentas cuya locación es Estados Unidos e Israel). A diferencia del subgrupo de los usuarios de Pakistán, algunos usuarios que interactúan con estos influencers mantienen interacciones con otros influencers dentro del grupo total de los  $m$  influencers considerados. Es por esto que en la figura 6.12 tienen todos score parecido.

Podemos continuar con el proceso de remoción de influencers para ver la composición de la mayoría en la discusión climática. Al hacer esto, distinguimos nuevamente otros subgrupos que se separan en score por cuestiones geográficas. Como el objetivo de este trabajo es estudiar discusiones ambientalistas, no entraremos en detalle ni describiremos a estos subgrupos. Concluimos acá con el proceso iterativo de remoción de influencers para la COP21.

### 6.2.2. Filtrado iterativo de usuarios de la COP26


Análogamente a lo que hicimos en la COP21, en la figura 6.14 observamos la distribución de scores para la COP26 sin preseleccionar ningún conjunto de usuarios.

Se puede observar que solo un influencer se destaca del resto. Se trata de @AUPhackeray, un político de la India. Al analizar los tweets de este usuario, se puede notar que la separación con el resto de los influencers no tiene una connotación de crítica hacia las opiniones mainstream sobre el cambio climático. Por el contrario, @AUPhackeray defiende las propuestas de la COP26.



**Figura 6.14:** Distribución de scores de usuarios e influencers para la COP26


Siguiendo el camino que planteamos para la COP21, procedemos a remover de nuestra red a este influencer y a todos los usuarios que interactuaron con él pero que no interactuaron con al menos otros 2 influencers. En la figura 6.15 recalculamos la nueva distribución de scores de usuarios e influencers.



**Figura 6.15:** A la izquierda, distribución de scores de usuarios e influencers para la COP26, tras la remoción de 1 influencer. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

Notar que en la distribución de la figura 6.15 se distinguen dos grupos de influencers. El grupo mayoritario, con score menor a 0, se separa completamente del otro grupo con score mayor a 0. Este último, conformado por 8 influencers.

Observamos que de los 8 influencers, 2 son medios internacionales, 1 esta asociado a políticas del Reino Unido y 5 están basados en Corea del Sur y están directamente relacionados con el grupo musical coreano “BlackPink”. Esto tiene sentido, ya que BlackPink fue el grupo musical oficial de la COP26. Para confirmar si esto se trata de un sesgo poblacional, analizamos la distribución de ubicaciones de los influencers con score menor a 0 (la mayoría) y la distribución de ubicaciones de los influencers con score mayor a 0 (la mayoría). Estas distribuciones se pueden observar en la figura 6.16. Es importante destacar que, una vez más, no se pudo obtener información geográfica para todos los influencers de la mayoría. Se contabilizaron las ubicaciones de aproximadamente el 59% de los influencers de este subgrupo.



**Figura 6.16:** A la izquierda: Distribución de países de origen de los influencers con score < 0 (“la mayoría”) en la distribución de scores de influencers de la COP26 tras la remoción de 1 influencer. A la derecha: Distribución de países de origen de los 8 influencers con score > 0.

En el grupo de la mayoría, las ubicaciones principales son: el Reino Unido (UK), Estados Unidos y Canadá. Esto es comprensible, ya que estamos filtrando tweets en inglés y la COP26 se llevó a cabo en el Reino Unido. Por otro lado, en la minoría, la ubicación principal es Corea del Sur, locación que no se observa en la distribución de ubicaciones de la mayoría.


Analizamos los tweets de estos 8 influencers con score mayor a 0. Para ello, siguiendo un procedimiento similar al realizado para la COP21, visualizamos los tweets de estos influencers en forma de nube de palabras (ver figura 6.17), con el fin

de comprender por qué están vinculados a la discusión de la COP26.



**Figura 6.17:** Nube de palabras de los tweets de los influencers con score > 0 en la distribución de scores de los influencers de la COP26 tras la remoción de 1 influencer.


Se observa la presencia de varias palabras relacionadas con temas climáticos. Destaca la palabra “BlackPink”. Esto tiene sentido, ya que la cuenta oficial de la conferencia, @COP26, llevó a cabo una campaña publicitaria en Twitter utilizando al grupo musical BlackPink como parte de sus esfuerzos para concientizar sobre el cambio climático.



**Figura 6.18:** A la izquierda, distribución de scores de usuarios e influencers para la COP26, tras la remoción de 9 influencers. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

Continuando con el tercer paso en el proceso iterativo de filtrado de usuarios específicos, eliminamos al subgrupo de influencers relacionados con el grupo musical BlackPink y a los usuarios involucrados. La nueva distribución de scores de usuarios e influencers se puede ver en la figura 6.18.

Una vez más, aparece una clara distribución bimodal con un subgrupo minoritario con score mayor a 0. Este subgrupo está compuesto por 9 influencers procedentes de la India y 2 influencers procedentes de Israel. La mayoría de las cuentas están relacionadas con figuras políticas. Concluimos que esta distribución es bimodal debido a un sesgo geográfico que no está relacionado con la discusión ambientalista alrededor de la COP26. Procedemos a eliminar este subgrupo y a recalcular la distribución de scores. Esto se muestra en la figura 6.19.




**Figura 6.19:** A la izquierda, distribución de scores de usuarios e influencers para la COP26, tras la remoción de 20 influencers. A la derecha, descripción de los influencers del grupo minoritario con score cercano a 1.

La figura 6.19 muestra una distribución con tres modos distinguibles. El modo con score cercano a 0 contiene a los influencers de interés, los cuales analizaremos a continuación. Sin embargo, primero caracterizaremos el modo con score cercano a 1, el cual está compuesto por dos influencers: @PacheduZW y @ali\_naka. Estos dos influencers están asociados a organizaciones activistas no gubernamentales radicadas en África. @PacheduZW es una organización que busca proteger la democracia en Zimbabwe y @ali\_naka es un activista que aboga por los derechos de los africanos.

Parece que la separación de estas dos cuentas del resto de los influencers está relacionada con un sesgo geográfico asociado a África. Para comprender su participación en la discusión de la COP26, analicemos los tweets de este subgrupo. Una








**Figura 6.21:** Distribución de scores de usuarios e influencers para la COP26, tras la remoción de 22 influencers.

bución de la mayoría como la de la minoría. Esto indica que no hay una connotación geográfica en la separación de estos dos subgrupos.



**Figura 6.22:** A la izquierda, distribución geográfica de los influencers de la “mayoría” en la distribución de scores de influencers de la COP26, tras el filtrado de 22 influencers seleccionados. A la derecha, distribución geográfica de los influencers de la “minoría” en la distribución de scores de influencers de la COP26.


Ahora examinemos los tweets del grupo minoritario. Para ello, creamos, nuevamente, una nube de palabras. Esta se muestra en la figura 6.23.



## 6.3. Robustez del método: Definición de influencer

Tenemos una red de retweets para cada conferencia, donde cada usuario es un nodo y cada link representa un retweet. Identificamos 2 capas en la red y creamos una red bipartita. Siguiendo el enfoque propuesto por [1], una de las capas está compuesta por los  $m$  usuarios más retweeteados, a quienes llamamos “influencers”. La otra capa está formada por el resto de los usuarios que interactuaron con al menos dos de estos  $m$  influencers.

Queremos evaluar la robustez del método ante cambios en la definición de lo que consideramos como “influencer”. Para ello, definimos a los influencers como los  $m$  nodos con mayor centralidad de PageRank [44]. En la figura 6.24, se presentan las distribuciones de los scores de usuarios e influencers tanto para la COP21 como para la COP26 con esta nueva definición.



**Figura 6.24:** Espectro ideológico de la COP21 y de la COP26 tras definir como influencers a los  $m$  usuarios con mayor centralidad de PageRank. A la izquierda, distribución de scores de usuarios e influencers para la COP21. A la derecha, distribución de scores de usuarios e influencers para la COP26.

En la COP21, las distribuciones asociadas a influencers definidos mediante centralidad de grado y centralidad de PageRank comparten el 86 % de los influencers en total. En particular, comparten todos los influencers del subgrupo de la minoría, aunque con esta nueva definición, aparece otro influencer más: Tom Nelson (@tan123). Este individuo es un influencer con una perspectiva claramente centrada en el clima, donde se refiere a aquellos que tienen una perspectiva más convencional

sobre el cambio climático como “Climate Alarmists”.

En la COP26, las distribuciones asociadas a influencers definidos mediante centralidad de grado y centralidad de PageRank comparten el 80 % de los influencers en total y 34 influencers del subgrupo de la minoría. Observamos que los individuos identificados en la sección 4.2.2 como influencers con un enfoque climático, vuelven a estar presentes en el subgrupo de la minoría.

Cabe destacar que para llegar a las distribuciones que se muestran en la figura 6.24, pasamos por el proceso iterativo de remoción de influencers descrito en la sección 6.2. En la COP21, nuevamente se observa la presencia del subgrupo de influencers pakistaníes, mientras que en la COP26 se identifican subgrupos relacionados con el grupo musical BlackPink, políticos de la India y un nuevo subgrupo asociado al músico Shawn Mendes.

Concluimos que ambas definiciones de influencers son análogas, aunque la definición que involucra el cálculo de la centralidad de PageRank permite la detección de otro influencer relacionado con cuestiones climáticas en la minoría de la COP21.

## 6.4. Contribución en Python

Parte de este trabajo consistió en la creación de una librería de Python que permita la aplicación del método de Latent Ideology de forma general. La idea es que cualquier usuario, dado un dataset de interacciones (o edgelist) entre objetos de cualquier índole, pueda aplicar el método, definir los parámetros del modelo e introducir los filtrados típicos que detallamos en la sección 6.2 de forma fácil e intuitiva.

La librería, denominada “latent-ideology”, puede instalarse mediante “pip”. Pip es un sistema de administración de paquetes que permite que una librería se pueda distribuir y compartir fácilmente. Para instalar el paquete, simplemente se ejecuta el comando «pip install latent-ideology » en la terminal.

Toda la documentación y ejemplos de uso de la librería se encuentran disponibles en el repositorio de GitHub: [https://github.com/fedemoss/latent\\_ideology](https://github.com/fedemoss/latent_ideology)

### 6.4.1. Funciones principales del paquete

El paquete cuenta con 4 funciones principales.

La primera función se encarga de convertir un dataset de interacciones (o edgelist) entre targets y sources, en una matriz de adyacencia bipartita. En esta matriz, un layer representa a los  $m$  sources con mayor centralidad de grado, y el otro layer incluye a los targets que interactuaron con al menos  $n$  sources. Además, esta función

permite aplicar filtros para limitar la presencia de targets con más de  $k$  interacciones totales, y también permite al usuario filtrar targets y sources tras seleccionar subgrupos específicos de sources mediante el atributo “drop”.

La segunda función aplica el método de Latent Ideology al layer de los targets. Recibe como input la matriz de adyacencia bipartita y devuelve un conjunto de datos en forma de un Pandas DataFrame con los scores de cada target.

Cabe destacar que dentro de esta función, a partir del atributo “dimension”, podemos controlar el truncado en la descomposición en SVD. De esta forma, el usuario puede explorar un Latent Ideology multidimensional.

Luego, tenemos dos funciones adicionales para aplicar el método de manera rápida y directa: «`apply_method()`» y «`apply_simplified_method()`». Estas funciones se encargan de todo, desde el filtrado con parámetros y sources específicas hasta la aplicación del método y el cálculo de los scores de las sources. El resultado de estas funciones puede variar desde solo los scores de targets y sources hasta conjuntos de datos con distribuciones de targets que interactuaron con cada source y distribuciones de sources que interactuaron con cada target.

# Agradecimientos

A mi madre y a mi padre, por su incondicional apoyo y su amor absoluto.

A Dani, por su paciencia  $\rightarrow \infty$ .

A Pablo y Seba, por mostrarme lo divertido que es jugar a investigar, y lo difícil que es hacerlo bien.

Al FCEN, que tantas experiencias me hizo vivir.

# Bibliografía

- [1] M. Falkenberg, A. Galeazzi y M. et al. Torricelli. “Growing polarization around climate change on social media”. En: *Nature Climate Change* 12 (2022), 1114–1121. DOI: 10.1038/s41558-022-01527-x.
- [2] John Cook et al. “Quantifying the consensus on anthropogenic global warming in the scientific literature”. En: *Environmental Research Letters* 8.2 (2013), pág. 024024. DOI: 10.1088/1748-9326/8/2/024024. URL: <https://dx.doi.org/10.1088/1748-9326/8/2/024024>.
- [3] Karen M. Douglas y Robbie M. Sutton. “The conspiracy-effect: Exposure to conspiracy theories (about global warming) decreases pro-social behavior and science acceptance”. En: *Personality and Individual Differences* 87 (2015), págs. 171-173. DOI: 10.1016/j.paid.2015.07.045. URL: <https://doi.org/10.1016/j.paid.2015.07.045>.
- [4] Public Policy Polling. *Conspiracy Theory Poll Results*. 2013. URL: [https://www.publicpolicypolling.com/wp-content/uploads/2017/09/PPP\\_Release\\_National\\_ConspiracyTheories\\_040213.pdf](https://www.publicpolicypolling.com/wp-content/uploads/2017/09/PPP_Release_National_ConspiracyTheories_040213.pdf).
- [5] Susanne Moser y Lisa Dilling. “Communicating Climate Change: Closing the Science-Action Gap”. En: *The Oxford Handbook of Climate Change and Society* (ene. de 2012). DOI: 10.1093/oxfordhb/9780199566600.003.0011.
- [6] *Conference of the Parties (COP)*. <https://unfccc.int/process/bodies/supreme-bodies/conference-of-the-parties-cop>. [Accedido el 18 de mayo de 2023].
- [7] Maxwell Boykoff et al. “Media and climate change observatory special issue: A review of media coverage of climate change and global warming in 2020”. En: *Cooperative Institute for Research in Environmental Sciences* 10.10 (2021), 10.25810/2nc9-bj43.
- [8] Anja Schmidt, Adriana Ivanova y Mike S Schäfer. “Media attention for climate change around the world: A comparative analysis of newspaper coverage in 27 countries”. En: *Global Environmental Change* 23 (2013), pág. 1233.



- [9] United Nations Framework Convention on Climate Change (UNFCCC). *The Paris Agreement*.
- [10] Mike S. Schäfer y Peter North. “Are social media making constructive climate policymaking harder?” En: *Contemporary Climate Change Debates*. Routledge, 2019, págs. 222-235.
- [11] Jean Burgess y Nancy K. Baym. *Twitter*. New York University Press, 2020.
- [12] Andranik Tumasjan et al. “Predicting Elections with Twitter: What 140 Characters Reveal about Political Sentiment”. En: vol. 10. Ene. de 2010.
- [13] David Garcia et al. “The digital traces of bubbles: Feedback cycles between socio-economic signals in the Bitcoin economy”. En: *Journal of the Royal Society, Interface / the Royal Society* 11 (ago. de 2014). DOI: 10.1098/rsif.2014.0623.
- [14] Twitter. *About Twitter verified accounts*. URL: <https://help.twitter.com/es/managing-your-account/about-twitter-verified-accounts>.
- [15] Livia van Vliet, Petter Törnberg y Justus Uitermark. “The Twitter parliamentary database: Analyzing Twitter politics across 26 countries”. En: (2020). DOI: 10.1371/journal.pone.0237073. URL: <https://doi.org/10.1371/journal.pone.0237073>.
- [16] P. Barberá. “Birds of the Same Feather Tweet Together: Bayesian Ideal Point Estimation Using Twitter Data”. En: *Political Analysis* 23.1 (2015), págs. 76-91. DOI: 10.1093/pan/mpu011.
- [17] P. Hoff, A. E. Raftery y M. S. Handcock. “Latent space approaches to social network analysis”. En: *Journal of the American Statistical Association* 97 (2002), 1090–1098. DOI: 10.1198/016214502388618906.
- [18] P. Barberá et al. “Tweeting From Left to Right: Is Online Political Communication More Than an Echo Chamber?” En: *Psychological Science* 26.10 (2015), 1531–1542. DOI: 10.1177/0956797615594620.
- [19] James Flamino, Alessandro Galezzi y Stuart Feldman et al. “Shifting Polarization and Twitter News Influencers between two U.S. Presidential Elections”. En: (). eprint: arXiv:2111.02505v1. URL: <https://doi.org/10.48550/arXiv.2111.02505>.
- [20] Michael Greenacre. *Correspondence Analysis in Practice*. CRC Press, 2007, pág. 202. ISBN: 9781584886167.
- [21] N. Benjamin Erichson et al. “Randomized Matrix Decompositions Using R”. En: (). eprint: arXiv:1608.02148.

- 
- [22] J. A. Hartigan y P. M. Hartigan et al. “The dip test of unimodality”. En: *Annals of statistics* (1985).
- [23] Jacob Devlin et al. “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. En: (2018).
- [24] Manuel Sánchez Mascarell. “Clasificación de textos basado en los modelos pre-entrenados BERT”. En: (2021).
- [25] D. M. Blei, A. Y. Ng y M. I. Jordan. “Latent Dirichlet Allocation”. En: *Journal of Machine Learning Research* 3 (2003), págs. 993-1022.
- [26] Maarten Grootendorst. “BERTopic: Neural topic modeling with a class-based TF-IDF procedure”. En: *arXiv preprint* (2022). eprint: arXiv:2203.05794.
- [27] Gerard Salton y Chris Buckley. “Term-weighting approaches in automatic text retrieval”. En: *Information Processing & Management* 24.5 (1988), págs. 513-523.
- [28] Vincent Blondel et al. “Fast Unfolding of Communities in Large Networks”. En: *Journal of Statistical Mechanics Theory and Experiment* 2008 (abr. de 2008). DOI: 10.1088/1742-5468/2008/10/P10008.
- [29] Vincent D Blondel et al. “Fast unfolding of communities in large networks”. En: *Journal of Statistical Mechanics: Theory and Experiment* 2008.10 (2008), P10008. DOI: 10.1088/1742-5468/2008/10/P10008. URL: <https://dx.doi.org/10.1088/1742-5468/2008/10/P10008>.
- [30] Miller McPherson, Lynn Smith-Lovin y James M Cook. “Birds of a feather: Homophily in social networks”. En: *Annual review of sociology* 27.1 (2001), págs. 415-444.
- [31] Mark EJ Newman. “Mixing patterns in networks”. En: *Physical Review E* 67.2 (2003), pág. 026126.
- [32] Juergen Pfeffer, Daniel Matter y Anahit Sargsyan. “The Half-Life of a Tweet”. En: (2023).
- [33] United Nations Framework Convention on Climate Change (UNFCCC). *Report of the Conference of the Parties serving as the meeting of the Parties to the Paris Agreement (CMA), Tenth part, Addendum, Volume I*. Retrieved from [https://unfccc.int/sites/default/files/resource/cma2021\\_10\\_add1\\_adv.pdf](https://unfccc.int/sites/default/files/resource/cma2021_10_add1_adv.pdf). 2021.
- [34] J. Farrell, K. McConnell y R. Brulle. “Evidence-based strategies to combat scientific misinformation”. En: *Nature Climate Change* 9 (2019), pág. 191.

- [35] The Scotsman. *COP26: Nicola Sturgeon says climate conference poses threat to increase Covid infections*. Accessed May 2023. Available at: <https://www.scotsman.com/health/coronavirus/cop26-nicola-sturgeon-says-climate-conference-poses-threat-to-increase-covid-infections-3433746>.
- [36] Diaz Ruiz, Carlos and Nilsson, Tomas. “Disinformation and Echo Chambers: How Disinformation Circulates on Social Media Through Identity-Driven Controversies”. En: *Journal of Public Policy and Marketing* 42.1 (2023), págs. 18-35. ISSN: 0743-9156. DOI: 10.1177/07439156221103852.
- [37] C. Thi Nguyen. “ECHO CHAMBERS AND EPISTEMIC BUBBLES”. En: *Episteme* 17.2 (2020), págs. 141-161. ISSN: 1742-3600. DOI: 10.1017/epi.2018.32.
- [38] Matteo Cinelli et al. “The echo chamber effect on social media”. En: *Proceedings of the National Academy of Sciences* 118.9 (2021). DOI: 10.1073/pnas.2023301118. URL: <https://doi.org/10.1073/pnas.2023301118>.
- [39] Wikipedia. *Steve Baker (politician) – Wikipedia, The Free Encyclopedia*. Accessed May 2023. 2023. URL: [https://en.wikipedia.org/wiki/Steve\\_Baker\\_\(politician\)](https://en.wikipedia.org/wiki/Steve_Baker_(politician)).
- [40] Pakistan Tehreek-e-Insaf. *What is PTI*. Accessed May, 2023. Retrieved from <https://www.insaf.pk/what-is-pti>.
- [41] Wikipedia, the free encyclopedia. *Billion Tree Tsunami*. [https://en.wikipedia.org/wiki/Billion\\_Tree\\_Tsunami](https://en.wikipedia.org/wiki/Billion_Tree_Tsunami). Accessed: May 2023.
- [42] Amnesty International. *Zimbabwe: Mnangagwa’s First Year in Office Marked by a Systematic and Brutal Crackdown on Human Rights*. <https://www.amnesty.org/en/latest/press-release/2019/08/zimbabwe-mnangagwas-first-year-in-office-marked-by-a-systematic-and-brutal-crackdown-on-human-rights/>. Accessed: May 2023. 2019.
- [43] Al Jazeera. *The Hypocrisy of Emmerson Mnangagwa*. Accessed: May 2023. 2021. URL: <https://www.aljazeera.com/opinions/2021/12/1/the-hypocrisy-of-emmerson-mnangagwa>.
- [44] Panpan Zhang, Tiandong Wang y Jun Yan. “PageRank centrality and algorithms for weighted, directed networks with applications to World Input-Output Tables”. En: *arXiv preprint arXiv:2104.02764* (2021). Last revised: 16 May 2021. URL: <https://doi.org/10.48550/arXiv.2104.02764>.



Tesis disponible bajo licencia CC: atribución – no comercial – compartir igual  
(by-nc-sa) 2.5 Argentina