

Informe de transparencia y equidad del modelo

01.09.2020

Informe de transparencia y equidad del modelo

01.09.2020

Content

1	Introducción	2		
2	Construcción de datos	3		
3	Transparencia	6		
3.1	Técnicas aplicadas	6		
3.1.1	Problema de dimensionalidad	6		
3.1.2	En base a libros leídos	7		
3.1.3	En base a libros recomendados	10		
3.1.4	En base al género	12		
3.1.5	Comparativa de vecinos	13		
			4. Equidad	16
			4.1 Análisis equidad para usuarios	16
			4.1.1 Análisis número de recomendaciones	16
			4.1.2 Análisis precisión del modelo	20
			4.2 Análisis equidad para autores/autoras	25
			5. Bibliografía	29

1 Introducción

El objeto del presente documento es **analizar la equidad** del modelo recomendador de libros, mediante métricas diseñadas por el proveedor encargado de la ejecución del proyecto piloto del recomendador de libros durante la fase de ajuste del modelo, para ver si así este promueve recomendaciones equánimes para diferentes subgrupos de la población y **analizar la transparencia**, mediante diferentes técnicas de visualización, con el objetivo de entender y explicar las decisiones que toman dichos modelos.

2. Construcción de datos

En este apartado se describen detalladamente los nuevos ficheros creados a partir de los datos proporcionados por la Generalitat de Catalunya. Se explicarán los pasos necesarios para la creación de estos nuevos ficheros y las columnas que los forman. La limpieza realizada para la creación de estos conjuntos de datos es la misma que la explicada en el documento [EQUIA_Análisis exploratorio recomendador de libros.docx](#) ya que, para la creación de estos nuevos *datasets*, se utilizan los ficheros [df_recomendador_transeunte_v2.csv](#) y [df_5000libros_50usuarios_transeunte_v2.csv](#). El primero, contiene los datos iniciales limpios y filtrados, y permite identificar a los usuarios temporales. El segundo, contiene los libros más leídos de los usuarios que tienen más de 50 préstamos. Para [más detalles](#) sobre la [creación](#) de estos dos [ficheros](#), [consultar](#) el apartado [3. Construcción de datos](#) del documento [EQUIA_Recomendador de libros_Informe de exploración de datos_v0.2.docx](#).

Con el fin de realizar diferentes análisis de equidad y transparencia, recogidos en este mismo documento, se han creado tres nuevos ficheros. El primero de ellos es [dataset_id_usuarios_id_libros.csv](#), que almacena la [matriz dispersa](#) calculada utilizando las columnas [RECORD#\(PATRON\)](#) y [RECORD#\(BIBLIO\)](#) del fichero [df_recomendador_transeunte_v2.csv](#). Esta matriz es la matriz usuarios-documentos utilizada para realizar las distintas recomendaciones y se compone de ceros y unos. Tras obtener esta matriz, se calcula para cada usuario, el [número total](#) de [libros](#) únicos que ha tomado prestados. Para ello, se [suman](#) todas las [posiciones](#) de una [fila](#) ([usuario](#)) que [contengan](#) un [uno](#). Este valor se recoge en la columna [Num_Lecturas](#) que formará parte de un nuevo fichero, [dataset_recomendaciones_total_usuarios.csv](#). A continuación, se calcula el [número](#) de [aciertos](#) de forma que, para cada usuario, se crea una lista con los [libros leídos](#) y otra lista que contenga los [14 primeros libros recomendados](#) por los [vecinos](#) más [cercanos](#) de cada usuario. Estas dos [listas](#) se [comparan](#) y se comprueba cuántos de estos [libros coinciden](#), siendo éstos el [número](#) de [aciertos](#) que se [guardarán](#) en la columna [Aciertos_Train](#).

Tras construir este fichero, se actualiza creando uno nuevo [dataset_max_recomendaciones_usuarios_biblio.csv](#) al que se [añade](#), [para cada usuario](#), el [número máximo](#) de libros que puede [recomendar](#) junto a los identificadores de sus 40 vecinos. Este valor se almacena en la columna [Num_Max_Recomendar](#) y se calcula creando una lista con todos los libros que han leído entre los vecinos de cada usuario al que se quiera recomendar y contando el número total de libros que se usuario no ha leído y que serían los candidatos a recomendarse.

Además de estos ficheros, se ha creado el Excel [Idioma.xlsx](#). Este fichero [Excel](#) ha sido [creado](#) utilizando el [contenido](#) del documento [BIG DATA_codis big data.docx](#) facilitado por la Generalitat de Catalunya. Contiene los [códigos](#) de la [columna PCODE4](#) presentes en [dicho documento](#) y su correspondencia. Este fichero ha sido utilizado para realizar un mapeo entre los códigos numéricos originales y el idioma al que se corresponde cada uno de ellos, almacenando el idioma del usuario en la columna [LANG_USER](#).

Por último, se ha creado el fichero [dataframe_correlaciones_genero_idioma_nacionalidad_estudios_v2.csv](#). Partiendo del fichero [df_recomendador_transeunte_v2.csv](#) y utilizando el contenido de la [columna TERRITORY](#) se calcula el número de libros que toma prestado cada usuario en las distintas provincias. Los casos donde la columna [TERRITORY](#) tome los valores [Biblioteques tècniques](#) y [Centres penitenciaris](#) son sustituidos por el valor [Altres](#). El resultado para cada usuario se almacena en las columnas: [Nbooks_Girona](#), [Nbooks_Tarragona](#), [Nbooks_Lleida](#), [Nbooks_Barcelona](#), [Nbooks_Ebre](#) y [Nbooks_Altres](#). Además de estas columnas, para cada usuario se añaden las siguientes columnas:

- [Nbooks](#). Esta columna representa el número total de libros que un usuario toma prestados. Se crea mediante la suma de todos los libros existentes en las columnas del tipo [Nbooks_provincia](#) mencionadas anteriormente.
- [Gender](#). Representa el género del usuario. Se construye con la información del fichero del que se parte haciendo un mapeo entre cada usuario y su género, es decir, mapeando cada valor de la columna [RECORD #\(PATRON\)](#) con su valor correspondiente de la columna [PCODE1](#).

- **Idioma.** Contiene el idioma de cada usuario. Se construye de forma análoga a la columna Gender pero utilizando la columna PCODE4 en lugar de PCODE1.
- **Nacionalidad.** Representa la nacionalidad de cada usuario. Se construye de forma análoga a la columna Gender pero utilizando la columna PCODE3 en lugar de PCODE1.
- **Nivel_Estudios.** Contiene el nivel de estudios de cada usuario. Se construye de manera análoga a la columna Gender pero utilizando la columna PCODE2 en lugar de PCODE1.
- **Age.** Indica la edad de cada usuario. Para ello, se utiliza la columna Edad creada anteriormente.
- **Age_Cat.** Representa la edad del usuario de manera categórica. En este caso no se realiza la misma división que la utilizada en la columna Edad_cat. Las categorías y rangos de edad utilizados en este caso son:
 - No_info – valores Nan.
 - Childish – de 2 a 12 años.
 - Teen – de 12 a 20 años.
 - Young – de 20 a 40 años.
 - Adult – de 40 a 60 años.
 - Retired – mayores de 60 años.

Para la regresión logística, sin embargo, ha sido necesario modificar este último fichero creado para la regresión lineal. Se realiza una regresión logística binaria por lo que se necesita que la variable dependiente sea categórica y binaria. Para ello, al utilizarse como variables dependientes tanto el número de libros como el número de libros por provincia, se ha calculado la mediana y la media, respectivamente, para poder fijar un umbral y hacer que estas variables tengan dos categorías. Una vez calculados los umbrales, se establecen los valores de las nuevas columnas de forma que haya dos categorías: mayor que el umbral y menor o igual que el umbral. Dichas variables se corresponden con la columna Nbooks y las columnas Nbooks_provincia del fichero [dataframe_correlaciones_genero_idioma_nacionalidad_estudios_v2.csv](#).

A continuación, se muestra una tabla resumen que recoge todos los ficheros utilizados en los distintos análisis realizados en este apartado. En ella, se indica el tamaño de los distintos ficheros explicados junto con una breve descripción de los mismos.

Nombre fichero	Tamaño fichero	Descripción
dataset_id_usuarios_id_libros.csv	191 MB	Conjunto de datos que contiene la matriz dispersa de usuarios - documentos.
dataset_recomendaciones_total_usuarios.csv	67,9 MB	Conjunto de datos que recoge el número de libros de cada usuario y el número de aciertos del recomendador de libros.
dataset_max_recomendaciones_usuarios_biblio.csv	243 MB	Conjunto de datos cuyo contenido es el mismo que el del fichero dataset_recomendaciones_total_usuarios.csv al que se ha añadido el número máximo de libros que puede recomendar junto con los identificadores de sus 40 vecinos.
Idioma.xlsx	14 kB	Tabla Excel que contiene el mapeo entre el idioma de usuario y su código identificador.

Nombre fichero	Tamaño fichero	Descripción
dataframe_correlaciones_genero_idioma_nacionalidad_estudios_v2.csv	24,7 MB	Conjunto de datos que contiene el número de libros por cada usuario y provincia, y todas las columnas PCODE, de la 1 a la 4. Ha sido utilizado en los análisis de correlación, de diferencia de medias y de regresión lineal explicados en el presente documento.

Tabla 1:Conjuntos de datos utilizados en los distintos análisis del recomendador de libros.

3. Transparencia

En este apartado se intenta representar como el modelo recomendador de libros selecciona los 40 vecinos más cercanos y como a partir de estos intenta construir las 14 recomendaciones de libros que se darán al usuario referencia. Debido a que el número de usuarios y libros es muy alto, 457711 usuarios y 356769 libros, el espacio de representación de éstos es de muy alta dimensionalidad. Como consecuencia, se ha intentado utilizar herramientas que ayuden a entender los datos y los modelos en este tipo de espacios complejos, tales como PCA (Principal component analysis) y T-SNE (t-distributed stochastic neighbor embedding). Estas herramientas reducen la dimensionalidad del espacio y por lo tanto simplifican y clarifican de manera notable su representación. Sin embargo, al no alcanzar con este modelo una visualización lo suficientemente aclaratoria y convincente, resulta más fácil entender el modelo simplemente explicando los pasos matemáticos que se han llevado a cabo para hacer las recomendaciones, puesto que el modelo de por sí es lo suficientemente simple.

Aclarado esto se hace un breve resumen de las técnicas utilizadas y las visualizaciones obtenidas con el fin de reflejar el trabajo realizado.

3.1 Técnicas aplicadas

Puesto que cada usuario se representa en función del número de libros que ha leído y no ha leído, un usuario se puede representar entonces en un espacio de 356.769 dimensiones (el número de libros), un vector de una longitud considerable y cuya visualización está sujeta a la cantidad de dimensiones. Para reducir este número de dimensiones y poder representar cada usuario en dos o tres dimensiones, se aplicará primero una descomposición en valores singulares para reducir cada punto a una dimensión inferior (y además tratar de reducir el ruido que pudiera estar presente en los datos), por ejemplo 50, y más tarde aplicar PCA (que es una técnica de reducción de dimensiones enfocada en conservar aquellas dimensiones/componentes que expliquen la mayor cantidad de varianza posible de los datos) o T-SNE (que es otra técnica de reducción de dimensiones más centrada en conservar las distancias de puntos cercanos y que se utiliza como alternativa al PCA al ser capaz de capturar patrones más complejos).

3.1.1 Problema de dimensionalidad

Uno de los principales problemas que surge al proyectar vectores de altas dimensiones en espacios de bajas dimensiones, en este caso 2 o 3, es el **crowding problem**. Este problema se refiere a la dificultad de conservar y representar adecuadamente las distancias medias al pasar de un espacio de dimensiones altas a uno de dimensiones mucho más reducidas, debido a que vectores separados en el espacio de alta dimensión pueden acabar en una misma posición al proyectarlos en el espacio de baja dimensión y por lo tanto la distancia entre vectores verse alterada y no ser consecuente con la realidad (Figura 1).

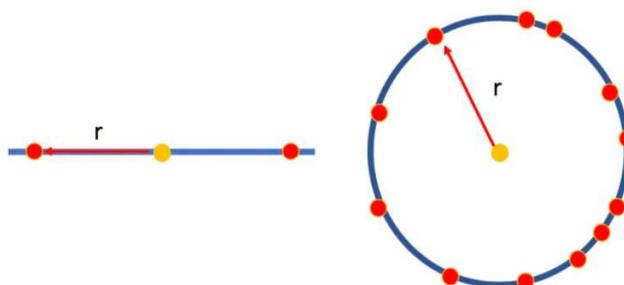


Figura 1: Ejemplo del crowding problem. Al pasar de 1 a 2 dimensiones, el número de puntos que están a distancia r respecto al punto amarillo pasa de 2 a ser cualquiera de los puntos que forman la circunferencia. El número de puntos equidistantes continúa creciendo drásticamente conforme se aumenta el número de dimensiones.

Para hacerse una idea del problema derivado de trabajar en altas dimensiones, como aquí el número de dimensiones está cerca de $p = 400.000$ y el número de vecinos que se toman son $k = 40$ (que representan un porcentaje del 1 por 10.000 respecto del total, es decir, la fracción del volumen del espacio es $r = 0.0001$), si los vecinos se distribuyesen uniformemente tomando valores entre 0 y 1 para cada dimensión, es de esperar que se necesitare buscar en un hipercubo de dimensión p y de lado $r^{1/p} = 0.99997$ para asegurar la búsqueda de sus vecinos. Pero fijándose en la longitud del lado (que será el intervalo de valores que puede tomar cada dimensión), a partir de él se puede deducir que la búsqueda es tan amplia en el rango de entrada que los vecinos podrían llegar a ser muy distintos entre sí.

En realidad, en el ejemplo actual las variables solo toman el valor 0 o 1 y se sabe que en muchas de ellas las observaciones coinciden, pero esto sirve para hacerse una idea de la dificultad de conservar la proximidad entre puntos al reducir dimensiones.

Como consecuencia de esta dificultad, y antes de aplicar PCA o T-SNE para visualizar la nube de puntos, es necesario realizar una primera reducción de dimensiones (que se hace mediante el método *TruncatedSVD* de la librería *sklearn*) por lo que en todos los casos se ha realizado una primera reducción de los datos a 50 dimensiones, y a partir de esta, se aplica PCA o T-SNE en cada caso según corresponda.

3.1.2 En base a libros leídos

Aquí cada usuario se representa como un vector de longitud 356.769 donde todas las posiciones son 0 salvo aquellas en las que se indica con un 1 que el libro ha sido leído una o más veces. Véanse varias formas de representación.

PCA

En este apartado se realizan diversas representaciones, tanto en 2D como 3D, de las primeras componentes principales; como sucede en el resto del capítulo, los 40 vecinos más cercanos en el espacio original (representados en color azul) no coinciden con los puntos más próximos al usuario principal (al que se realiza la recomendación y que aparece en color rojo) en la representación en baja dimensión en 2D (Figura 2) o 3D (Figura 3).

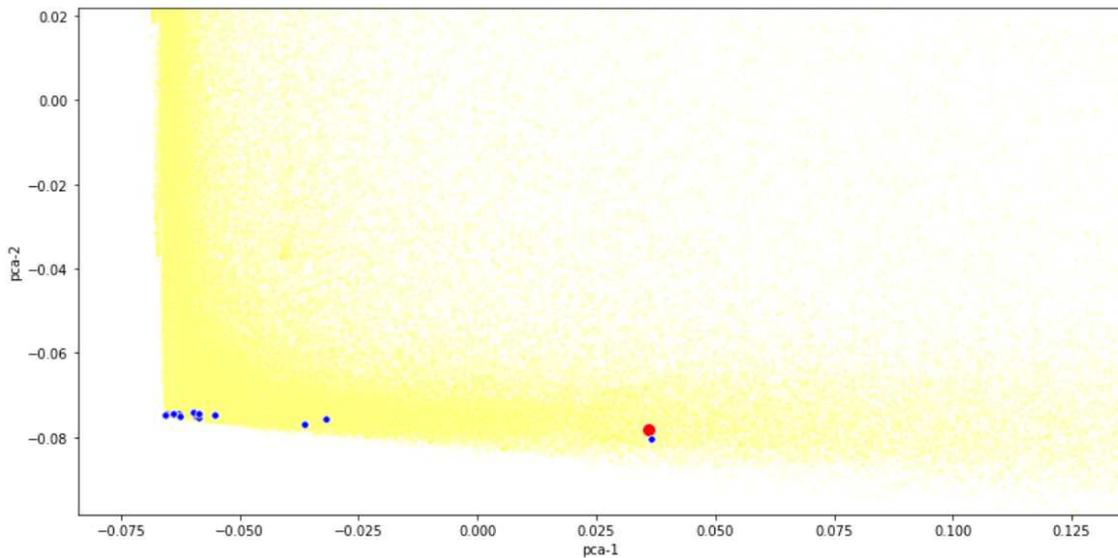


Figura 2: Representación de todos los usuarios en función de sus 2 primeras componentes principales. En color rojo el usuario al que se ofrece la recomendación, en color azul los 40 usuarios empleados en ella y en amarillo el resto de usuarios de la biblioteca.

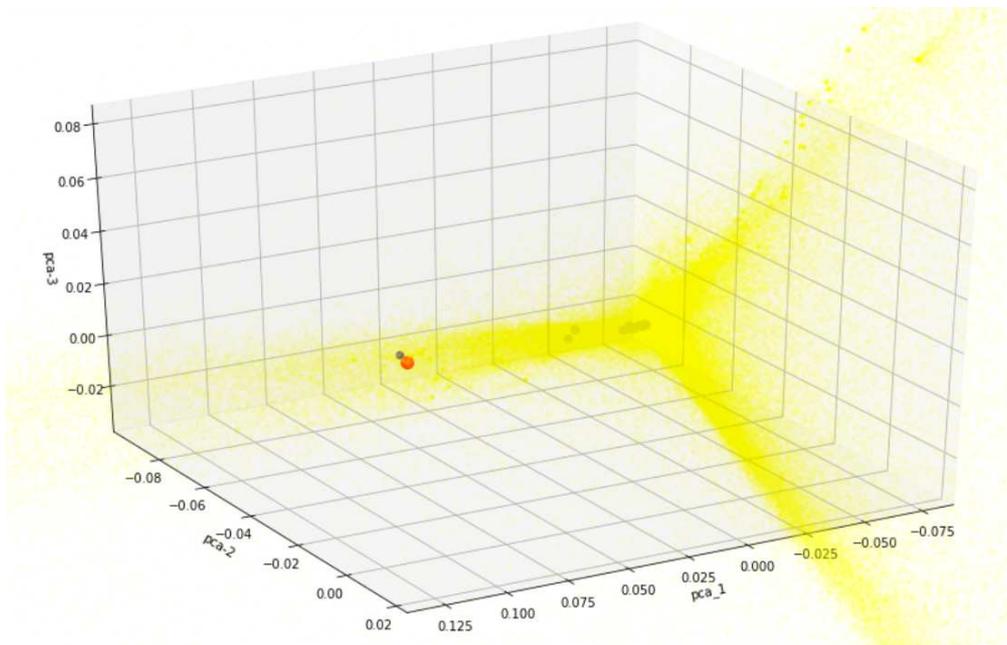


Figura 3 : Representación de los mismos puntos de la Figura 2 pero empleando las 3 primeras componentes principales.

Como se presumía con anterioridad, que los vecinos más cercanos (en azul) no sean los puntos más próximos en el espacio de representación puede ser debido al problema de tratar de conservar las dimensiones de un espacio de dimensión superior a uno inferior. Pero, además, es necesario aclarar que tampoco tienen por qué coincidir los vecinos del modelo con los de menor distancia en el espacio; explíquese esto último con el siguiente párrafo.

Por una parte, el modelo de bibliotecas calcula la distancia de Hamming entre los puntos que representan a cada usuario para elegir los vecinos correspondientes mientras que PCA proyectará cada punto sobre un eje y para ello se emplea la distancia euclídea. Esta diferencia en la elección de la distancia puede ser también otra razón de la diferencia entre las distancias de los puntos en el espacio original y en el representado. Ilústrese esta idea con el siguiente ejemplo:

Supóngase que se tienen 3 puntos, $(1,0)$, $(0,1)$ y $(1,1)$, y que se quiere calcular su distancia respecto al origen, $(0,0)$. Por una parte, con la distancia de Hamming que utiliza el recomendador, el punto $(1,1)$ está al doble de distancia del $(0,0)$ de lo que lo están los puntos $(1,0)$ y $(0,1)$, es decir, a distancia 2 en lugar de 1. Por su parte, con la distancia euclídea el punto $(1,1)$ está a distancia $\sqrt{2} \neq 2$ del origen y el resto también a distancia 1; es decir, el punto $(1,1)$ se representaría con PCA más cerca del origen de lo que en realidad está en el espacio original con la métrica original.

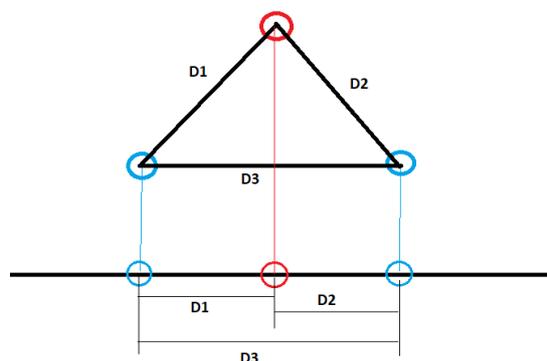


Figura 4: Proyección de 3 puntos equidistantes entre sí sobre un eje cualquiera.

Aunque con PCA los puntos equidistantes siguen a la misma distancia, las distancias originales entre puntos (su magnitud) se puede ver alterada y, además, con frecuencia no será posible mantener en el espacio de dimensiones bajas toda la información presente en el espacio de dimensiones altas; la Figura 4 es un simple ejemplo de ello: supóngase que el eje sobre el que se proyectan los vértices del triángulo equilátero se tomase como una de las componentes principales. En este caso las distancias $D1$ y $D2$ se conservarían, mostrando que la distancia del punto rojo es la misma a cada punto azul; sin embargo, la distancia $D3$ ya no refleja la distancia original entre los puntos azules, y esta es la pérdida de información a la que se hace referencia.

T-SNE

En este apartado se aplica T-SNE para tratar de representar todos los usuarios de la forma más fiel posible, marcando en color rojo el usuario principal (que recibe la recomendación), en color azul sus 40 vecinos (los que utiliza el modelo para realizar su recomendación correspondiente) y en amarillo el resto de puntos.

Debido a su naturaleza probabilística (se asocia a cada punto una distribución de probabilidad de la distancia del mismo respecto al resto, por lo que se obtiene una similitud entre pares de puntos que da lugar a una matriz de tamaño *número de observaciones x número de dimensiones*), cuando el número de observaciones supera varios miles, el tiempo de ejecución se vuelve excesivamente lento y esto es lo que se ha observado en este caso particular.

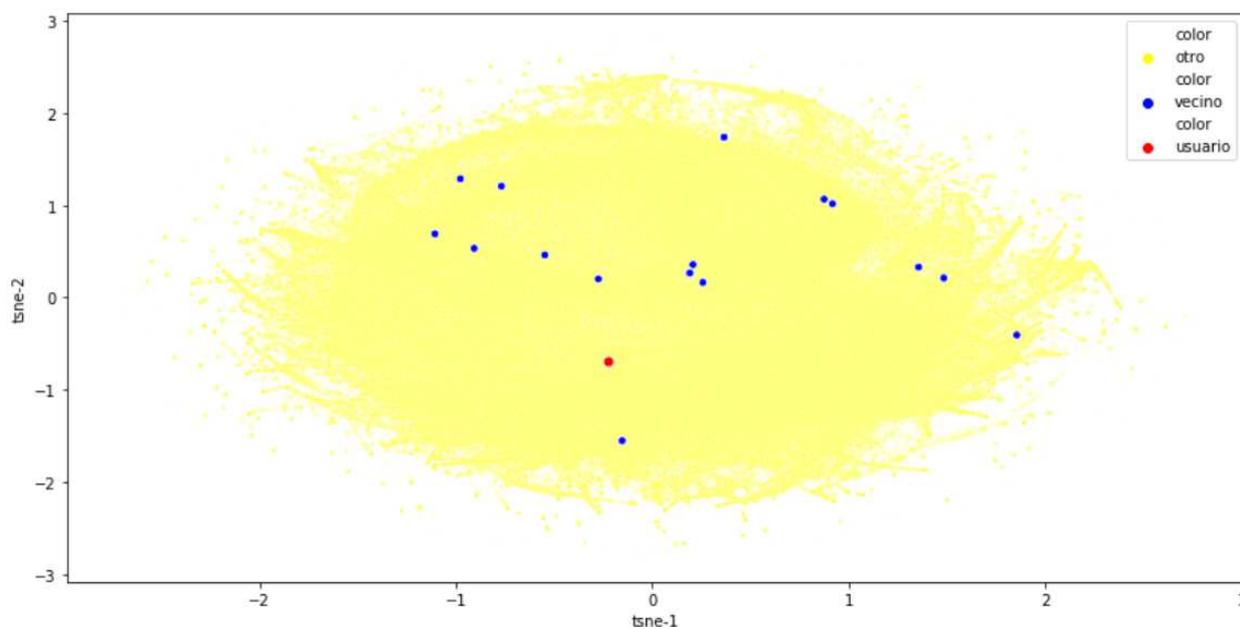


Figura 5: Representación, con T-SNE y valor de perplejidad 5, de los usuarios. Al igual que ocurría con la representación de las primeras componentes principales, los vecinos no se aproximan al usuario principal más de lo que lo hacen el resto de usuarios.

En resumen, la representación de usuarios (representados como vector one-hot) con PCA o T-SNE no resulta de gran ayuda para visualizar la elección que realiza el modelo de los vecinos correspondientes.

3.1.3 En base a libros recomendados

En este apartado se decide representar cada usuario como un vector que solo tenga 14 de sus posiciones con un 1, correspondientes a cada uno de los 14 libros que recibe como recomendación, y el resto de diferentes libros que se usan alguna vez como recomendación con un 0. Aquí, la longitud del vector es 95.964, menor que el primer apartado, ya que el total de libros recomendados no coincide con todos los libros disponibles. En las siguientes secciones se ofrecen las visualizaciones siguiendo el estilo que la sección anterior.

PCA

En este caso, observando la Figura 6, parece que los vecinos (puntos en color azul) están más cerca del usuario que recibe la recomendación de lo que lo estaban en el apartado anterior. Sin embargo, al centrarse en un entorno local alrededor del usuario principal (ver Figura 7), se comprueba que siguen existiendo multitud de usuarios más próximos que los propios vecinos.

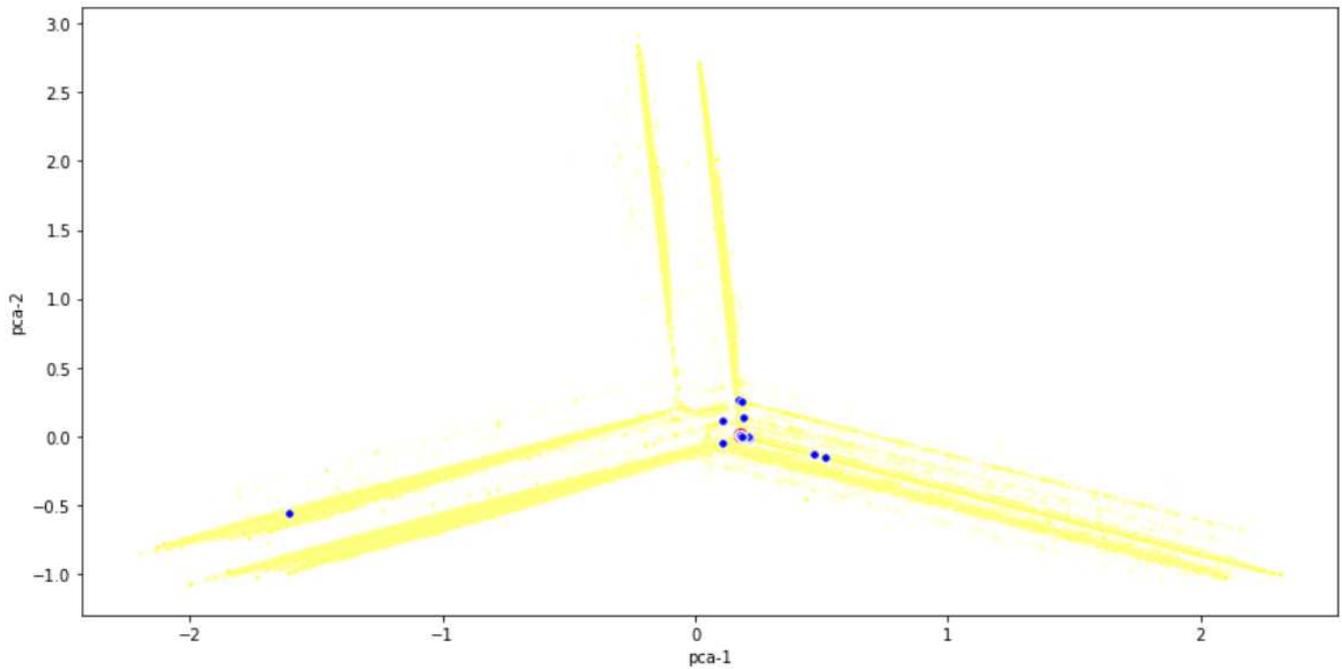


Figura 6: Representación de las 2 componentes principales de los usuarios según los libros que reciben como recomendación.

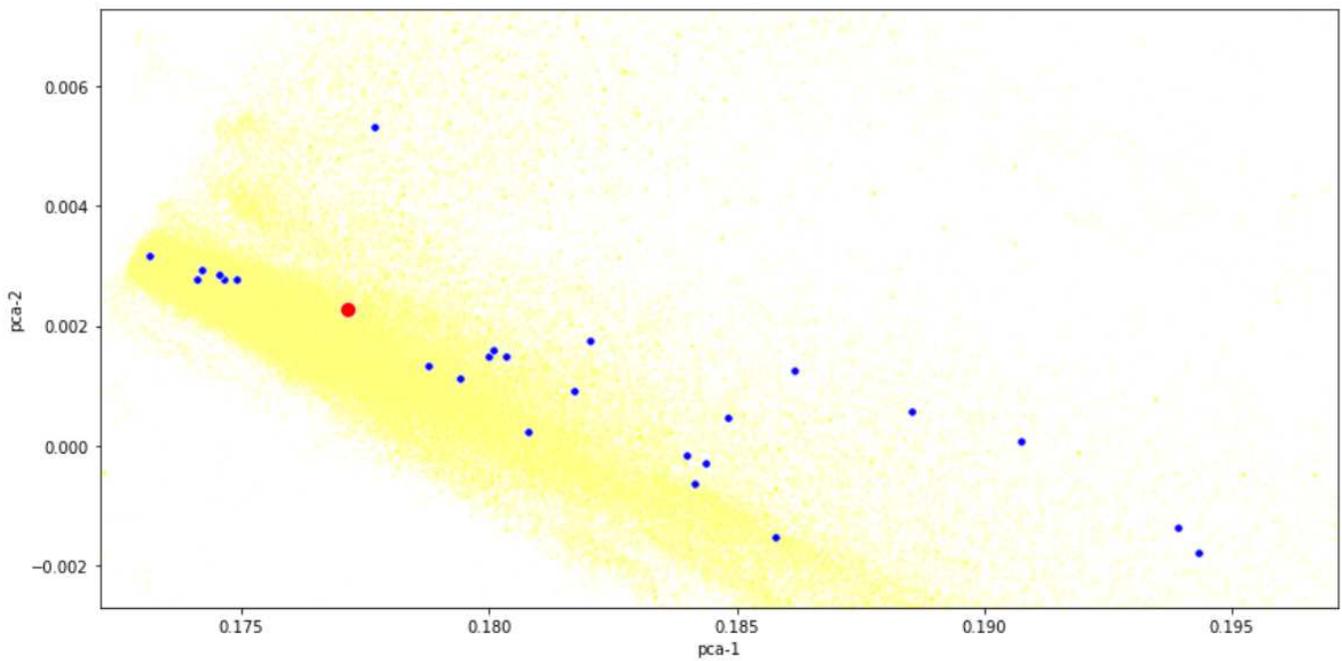


Figura 7: Zoom sobre la figura 14.

T-SNE

La representación con T-SNE (Figura 8) no aporta nada sobre la representación anterior con PCA.

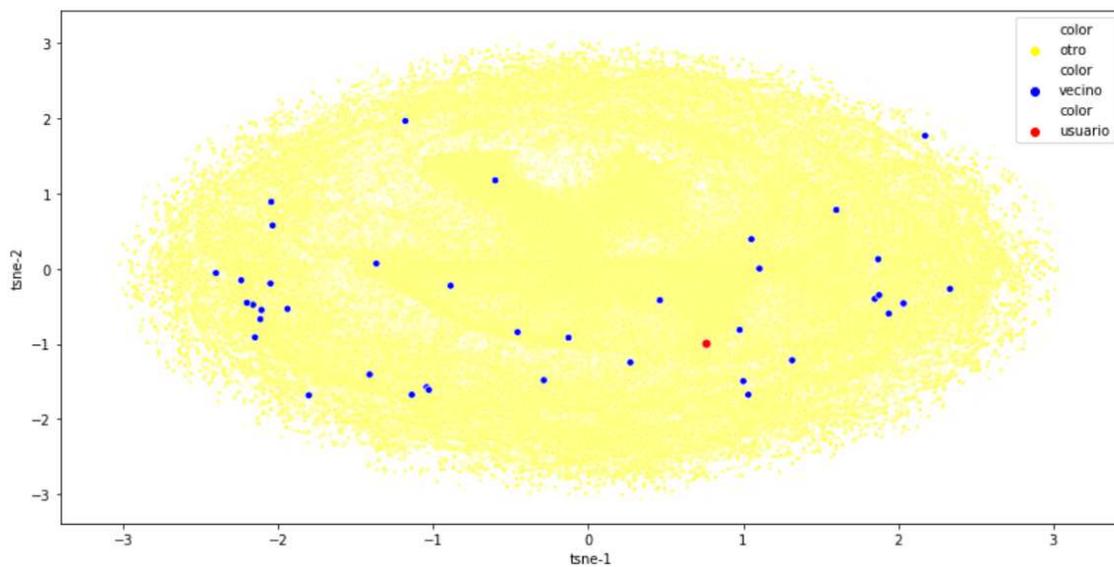


Figura 8: T-SNE de los usuarios representados en función de los libros que se les recomiendan.

3.1.4 En base al género

Representando los usuarios como vectores *one-hot* en función de los libros leídos, se decide intentar identificar algún agrupamiento de los usuarios en base a su género; a la vista de la Figura 9, **no se identifica ningún patrón**.

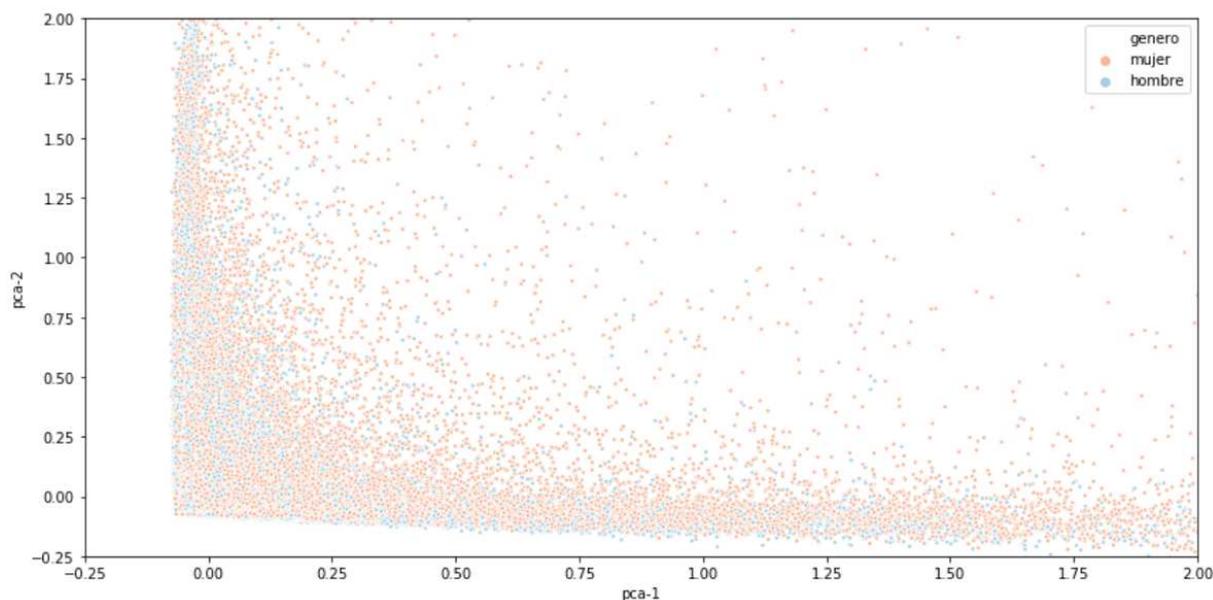


Figura 9: Representación, con PCA, de los usuarios según su género.

3.1.5 Comparativa de vecinos

Por último, otra forma de visualizar cómo escoge el modelo los usuarios más cercanos al usuario referencia es comparar los 40 vecinos que toma el modelo (representados en color turquesa en Figura 10) con los 40 vecinos que tienen un mayor número de libros prestados coincidentes, 1's, (representados en color morado en Figura 10) y los 40 vecinos con mayor número de libros no prestados, 0's (representados en amarillo en Figura 10).

Para ello, se elige un usuario con un número intermedio de libros, 22 en este ejemplo (que se representa por una estrella roja en Figura 10), se calculan los vecinos de cada una de las tres formas mencionadas y se ofrecen diferentes visualizaciones según las siguientes variables: distancia del vecino al usuario de referencia según el modelo, número de libros leídos por el usuario vecino y el número de libros del usuario de referencia que no ha leído el usuario vecino.

En la Figura 10 se comprueba cómo los usuarios obtenidos con el mayor número de coincidencias en 1's han leído de media varios libros menos libros que el resto (hacia abajo en el eje vertical) pero según el modelo están a distancias muy diversas (hacia la derecha en el eje X). Sin embargo, todos los vecinos con más coincidencias en 0's ocupan la misma posición, (1,21), mientras que los vecinos seleccionados por el modelo se reparten entre los puntos (2, 20), donde hay dos usuarios, el (7, 21) con un solo usuario y los 37 usuarios restantes en el (1,21).

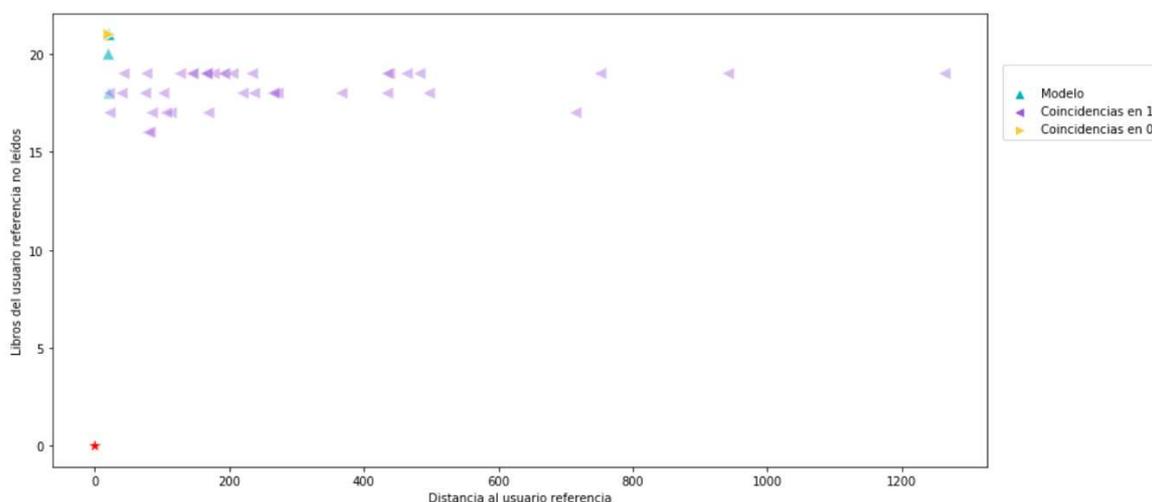


Figura 10: Representación de los 40 vecinos del modelo, los 40 usuarios más coincidentes en 1's (libros leídos) con el usuario referencia (representado por una estrella roja) y los 40 usuarios más coincidentes en 0's (libros no leídos) en función de la distancia a la que se encuentran del usuario referencia y del número de libros del usuario referencia que no han leído.

Esto se confirma atendiendo a la Figura 11, donde se observa que existe una correlación casi perfecta entre el número de libros que ha leído el usuario y la distancia a la que el modelo le sitúa respecto al usuario de referencia, lo que permite extraer algunas conclusiones acerca del comportamiento del modelo.

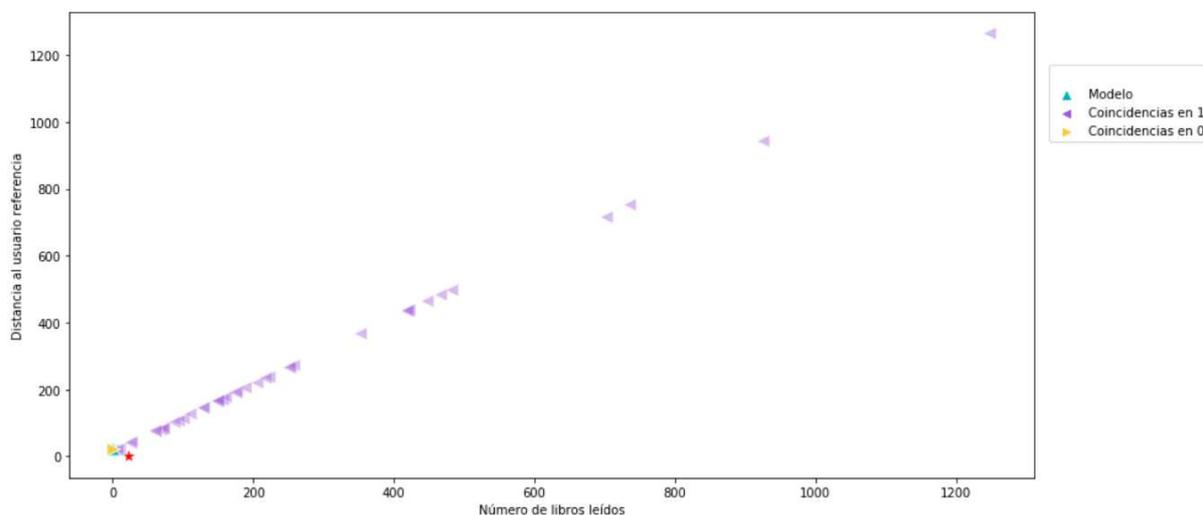


Figura 11: Representación de los 40 vecinos del modelo, los 40 usuarios más coincidentes en 1's (libros leídos) con el usuario referencia (representado por una estrella roja) y los 40 usuarios más coincidentes en 0's (libros no leídos) en función del número de libros leídos y de la distancia a la que se encuentran del usuario referencia.

Las figuras anteriores confirman que los usuarios vecinos seleccionados por el modelo leen de media muy pocos libros y por ello el número de libros que han leído en común es muy bajo. Del mismo modo, los usuarios con mayor número

de coincidencias en 0's (libros no leídos) no presentan ninguna otra característica que no sea usuarios con una sola lectura y coincidente con alguna del usuario de referencia.

Finalmente, los usuarios coincidentes en 1's (libros leídos) muestran una mayor variabilidad tanto en el número de libros leídos como en el número de libros leídos en común (ya que no son usuarios con una o dos lecturas iguales, sino que el rango va de 3 a 6 coincidencias); sin embargo, hay que resaltar que el modelo tiende a alejar estos últimos respecto al usuario de referencia, así que nunca serán escogidos por el modelo como vecinos.

Los más destacable se encuentra en la Figura 11, donde se observa que existe una relación lineal casi perfecta entre el número de libros que ha leído el usuario y la distancia a la que le sitúa el modelo respecto al usuario de referencia, lo que parece indicar que el número de libros que un usuario ha leído es determinante para el cálculo de la distancia que le asigna el modelo y, por tanto, también determinante para que se elija o no como un vecino.

4. Equidad

En el presente apartado se evaluará si el rendimiento del modelo utilizado para realizar la recomendación de libros es desigual y no equitativo para las diferentes subpoblaciones o grupos sensibles de usuarios y por lo tanto promueve algún tipo de discriminación.

4.1 Análisis equidad para usuarios

Para poder llevar a cabo la recomendación el modelo recomendador de libros tiene en cuenta los 40 vecinos más cercanos y en base a los libros que estos han leído recomienda 14 libros al usuario referencia. En consecuencia, para que el recomendador funcione eficazmente entre todos los vecinos tendrán que haber leído 14 libros de más diferentes al usuario referencia. Es decir, primeramente, se tendrá que ver cuántos de los libros recomendados han sido efectivamente leídos por los vecinos (y por lo tanto no son recomendaciones al azar o aleatorias) y después si estas recomendaciones son precisas. En esta sección se contemplarán ambos puntos.

4.1.1 Análisis número de recomendaciones

En este punto se describirá de los 14 libros recomendados cuantos han sido efectivamente prestados de usuarios vecinos y cuantos no, es decir cuántas de esas recomendaciones están basadas en los vecinos y cuantas son por azar. Además, se estudiará el problema en detalle teniendo en cuenta subpoblaciones sensibles a sufrir un trato desigual.

Para ello, los conjuntos de datos utilizado para realizar el siguiente análisis han sido `dataset_max_recomendaciones_usuarios_biblio.csv` y `dataframe_correlaciones_genero_idioma_nacionalidad_estudios_v2.csv`.

Composición de libros recomendados y vecinos

Como se ha comentado primeramente se ha de comprobar si el modelo es capaz de generar las suficientes recomendaciones no aleatorias para todos los usuarios, es decir 14 recomendaciones basadas en los libros prestados por los vecinos.

En la Figura 12 se representa la distribución de usuarios que reciben una recomendación de 14 libros con respecto a cuántos de estos libros no son recomendaciones aleatorias. El análisis se ha realizado teniendo en cuenta el número de libros que ha leído el usuario que recibe la recomendación, ya dependiendo de esto el número de recomendaciones no aleatorias varían.

Se observa claramente **el modelo tiene una tendencia clara a recomendar el máximo número recomendaciones no aleatorias, 14, a usuarios con mayor número de libros prestados** (Figura 12 barras azules). Sin embargo **a usuarios con un número medio de libro prestados** (Figura 12 barras amarillas) **tienen una mayor probabilidad de recibir menos de 2 libros como recomendación**, es decir, una mayor probabilidad de recibir al menos 12 recomendaciones aleatorias.

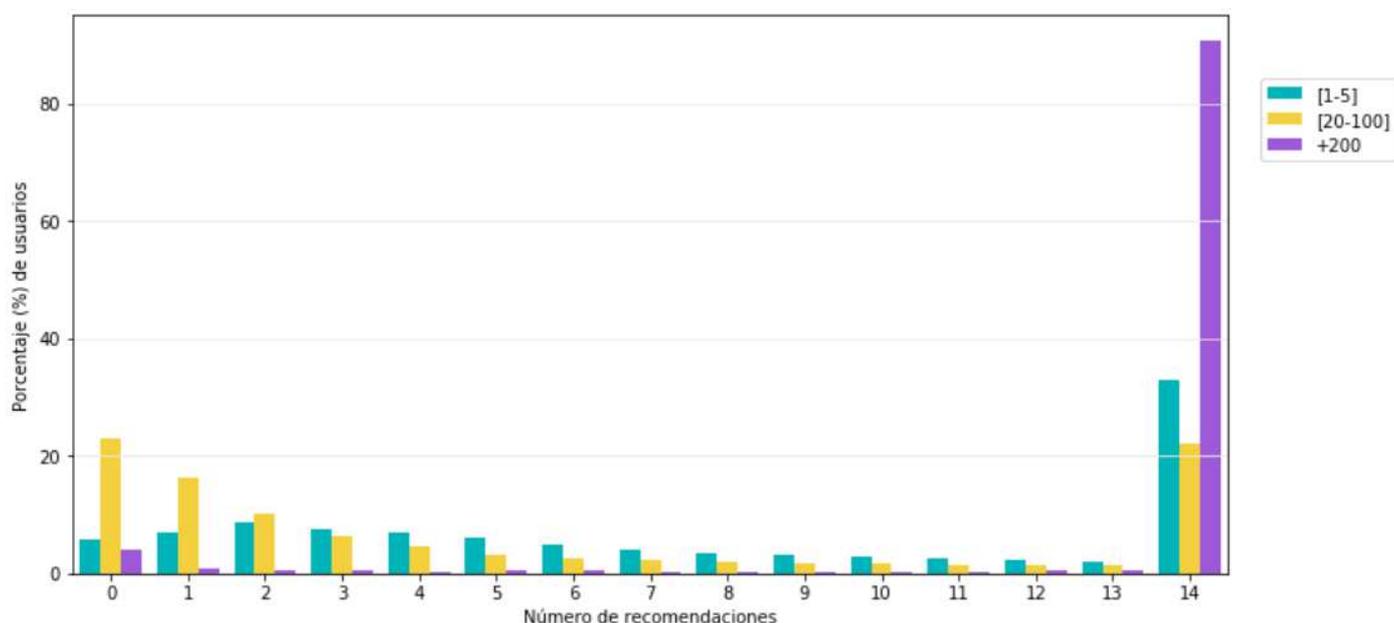


Figura 12: Distribución de una selección de usuarios (con menos de 5 libros, entre 20 y 100 libros y con más de 200 libros) según el número de recomendaciones no aleatorias que reciben. Cada uno de los grupos de usuarios ha sido normalizado.

Estas diferencias observadas en cuanto al número de libros prestados afectarán a los usuarios de forma desigual y en la práctica supondrán una situación de tratamiento desigual.

Viendo que varios usuarios muchos usuarios reciben recomendaciones aleatorias, cabría preguntarse qué tipo de usuarios componen el conjunto de 40 vecinos. Para arrojar algo de luz en este sentido, se va a presentar un ejemplo concreto que ayuda a aclarar el comportamiento del modelo en la práctica. En la Figura 13 se presenta un usuario referencia cuyo número de libros leídos es 4 junto con sus 7 vecinos más cercanos según el modelo recomendador (y por lo tanto a priori más similares al usuario referencia), para cada caso se indica el índice de los libros que ha leído.

En el caso anterior, los índices de los libros leídos que ha leído el usuario p20445027 que recibe la recomendación son: [229636, 239156, 264921, 270549].

Y los índices de los libros leídos por sus 7 primeros vecinos son:

- El usuario p26594651 ha leído los libros [239156].
- El usuario p21961980 ha leído los libros [229636].
- El usuario p17684377 ha leído los libros [142863, 239156].
- El usuario p22085786 ha leído los libros [235470, 264921].
- El usuario p28667098 ha leído los libros [248532, 270549].
- El usuario p26625921 ha leído los libros [69243].
- El usuario p19830087 ha leído los libros [275068].

Figura 13: En la imagen se muestran, por orden de similitud, los índices de los libros leídos por los usuarios más próximos al usuario al que se realiza la recomendación en la figura anterior.

Fíjese en que los dos primeros usuarios tienen una única lectura y esta es coincidente con uno de los libros leídos por el usuario principal. Los siguientes tres usuarios tienen dos libros y una de ellas coincidente con las del usuario referencia (es decir, ambos lo han leído), y el resto de los 35 usuarios tienen solo una sola lectura (Figura 13 muestra solo el sexto

y séptimo usuario). Por lo tanto, estos 35 usuarios al tener solo un libro prestado y no tener ninguno coincidente con el usuario referencia son usuarios aleatorios y como consecuencia generan las recomendaciones aleatorias que se han descrito con anterioridad. La razón base por la que ocurre esto es que los vecinos se eligen minimizando la distancia entre usuario referencia y vecinos, es decir maximizando las coincidencias entre ellos. Como estas coincidencias son tanto en libros prestados como en no prestados y al haber muchos más libros no prestados, puesto que el catálogo de Bibliografics es muy extenso, la selección de vecinos en muchas ocasiones se guía principalmente por las coincidencias en libros no prestado, eligiendo así vecinos con pocos libros prestados y como consecuencia generando así recomendaciones aleatorias.

Evaluación de número de recomendaciones por género de usuario

Con el fin de evaluar si el número de libros leídos por vecinos que se le recomiendan a los usuarios referencia hombres o mujeres es desigual, se ha procedido a calcular este número por género de usuario. Aunque en las gráficas se incluya la categoría -, para el análisis posterior únicamente se han tenido en cuenta usuarios con género Dona o Home, ya que las demás categorías no están determinadas y generan ruido estadístico.

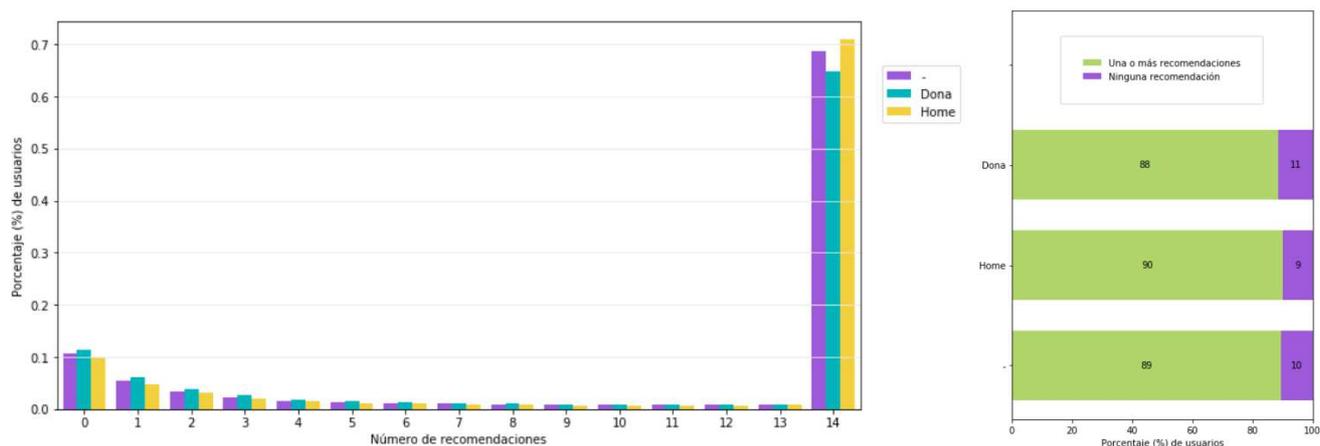


Figura 14: Distribución usuarios (%) con respecto al número de recomendaciones no aleatorias por género de usuario. Derecha: Porcentaje de usuarios para cada posible número de recomendaciones no aleatorias y cada posible género. Izquierda: Porcentaje de usuarios por categoría de género que reciben ninguna o alguna recomendación no aleatoria.

Tal y como se observa en la Figura 14, es importante destacar que para ambos géneros las distribuciones por número de recomendaciones no aleatorias son similares (Figura 14 izquierda), lo cual consecuentemente se traslada a la gráfica simplificada con el porcentaje de usuarios con ninguna o alguna recomendación no aleatoria (Figura 14 izquierda). Esta similitud queda reflejada en el test Chi-cuadrado de Pearson que devuelve un valor del estadístico igual a 202,10 con un valor p cercano a 0 y una Phi de Cramer, de 0,02, es decir se puede concluir que el grado de asociación de las variables porcentaje de usuarios y género es casi insignificante, es decir para los diferentes géneros no hay diferencias significativas entre el porcentaje de usuarios.

Evaluación de número de recomendaciones por edad de usuario

Al igual que en el género, también se ha evaluado si el número de libros leídos por vecinos que se le recomiendan a los usuarios referencia es desigual por edad de usuario.

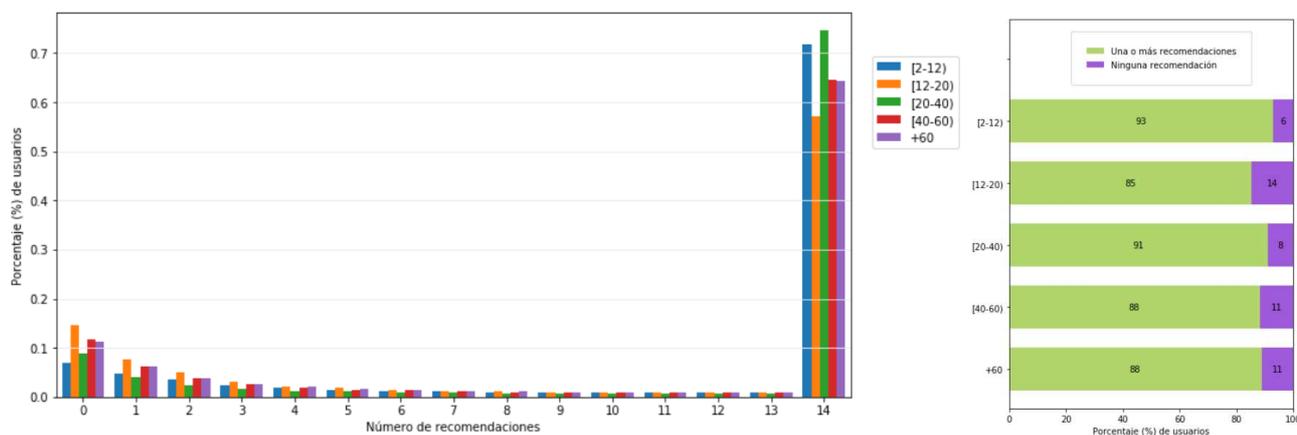


Figura 15: Distribución de la cantidad de recomendaciones nulas (es decir, ningún libro) según la franja de edad del usuario.

Para todas las categorías de edad la distribución de usuarios que tienen alguna o ninguna recomendación no aleatoria es similar (Figura 15). Esta similitud queda igualmente evidenciada en el test Chi-cuadrado de Pearson que devuelve un valor del estadístico igual a 2.129,80 con un valor p cercano a 0 y una Phi de Cramer, de 0,07, es decir se puede concluir que el grado de asociación de las variables porcentaje de usuarios y edad de usuario es casi insignificante, es decir para las diferentes edades no hay diferencias significativas entre el porcentaje de usuarios y por lo tanto **no parece haber desigualdad con respecto al número de recomendaciones no aleatorias**.

Evaluación de número de recomendaciones por número de libros leídos por el usuario

Visto que el número de libros prestados por el usuario referencia es una variable determinante para seleccionar los vecinos y por lo tanto construir las recomendaciones (Figura 12), se ha evaluado si el número de libros leídos no aleatorios que se le recomiendan a los usuarios referencia es desigual teniendo en cuenta el número de libros que ellos mismos leen.

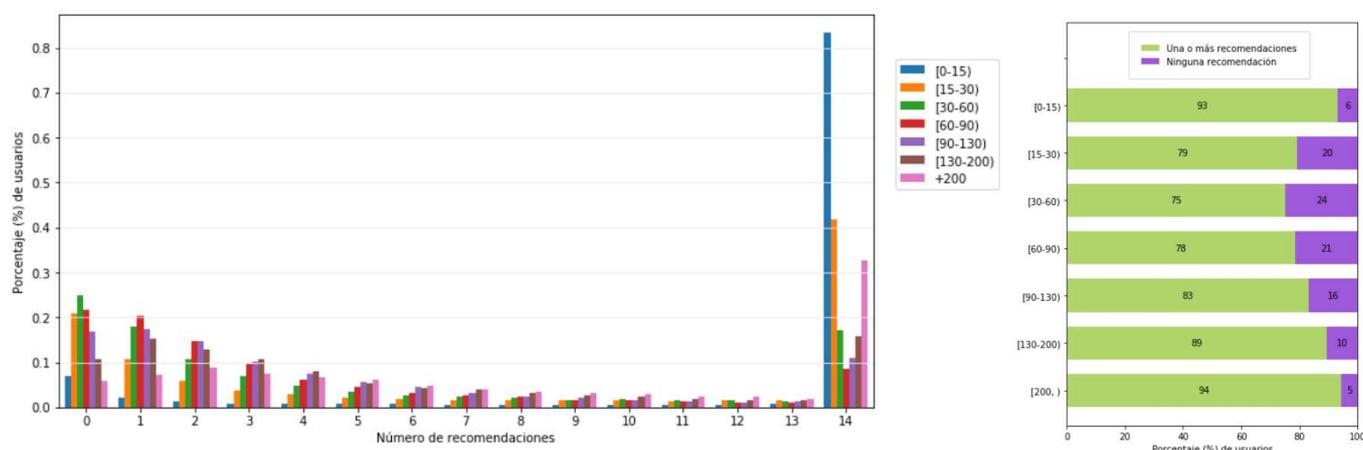


Figura 16: Distribución de la cantidad de recomendaciones nulas (es decir, ningún libro) según la categoría de número de libros.

Como se puede ver en figura izquierda de Figura 16, las principales diferencias entre las categorías, para diferentes intervalos de número de libros prestados por el usuario referencia, es para cuando se realizan 14 recomendaciones no aleatorias. Esto genera consecuentemente diferencias en la proporción de usuarios que reciben una o más recomendaciones no aleatorias (Figura 16 derecha verde) que quedan evidenciadas con el test Chi-cuadrado de Pearson. El valor del estadístico es muy alto, 21,68 con un valor p asociado de 0 y un λ de Cramer de 0,21, lo cual informa de que existe una asociación entre las variables número de libros y ninguna o varias recomendaciones no aleatorias y que ésta es entre débil y moderada, es decir existe un trato desigual según el número de libros prestados que tenga el usuario.

4.1.2 Análisis precisión del modelo

Para poder evaluar el comportamiento del modelo, se aprovechó la métrica de precisión ya diseñada y utilizada durante el entrenamiento y ajuste de los hiperparámetros del modelo. En concreto los pasos llevados a cabo para calcular esta precisión son los siguientes:

1. Para un usuario dado se eliminan 10 libros que le hayan sido prestados y que serán denominados libros referencia.
2. Una vez eliminados los libros referencia, se aplica el recomendador de libros a este usuario (utilizando los hiperparámetros fijados por el proveedor del recomendador de libros) y se obtienen 14 libros recomendados.
3. Se comparan los 14 libros recomendados y los 10 libros referencia y se contabiliza cuantos de los libros referencia han sido acertadamente recomendados. La precisión para un usuario dado vendrá por lo tanto dada por el número de libros acertados.

$$\text{Precisión por usuario} = \text{Libros referencia} \cap \text{Libros recomendados}$$

4. El proceso se repite para cada uno de los usuarios y se calcula la precisión para cada uno de ellos.

El conjunto de datos utilizado para realizar el siguiente análisis ha sido `argus_top_5000_books.csv` provisto por la Generalitat de Catalunya. Debido a que, como se ha comentado, para cada usuario se eliminan 10 libros como set de referencia, a la hora de seleccionar los usuarios a los que recomendar solo se han tenido en cuenta aquellos que tienen al menos 11 libros prestados. Además, con el fin de comparar los resultados con los resultados obtenidos durante el entrenamiento del modelo se ha considerado también el subgrupo de usuarios utilizados para ajuste del modelo, es decir, aquellos usuarios que tienen un mínimo de 50 libros prestados. En la Figura 17 se muestra el porcentaje de

usuarios para cada una de las posibles precisiones, es decir el porcentaje de usuarios versus el número de libros acertados por el modelo recomendador.

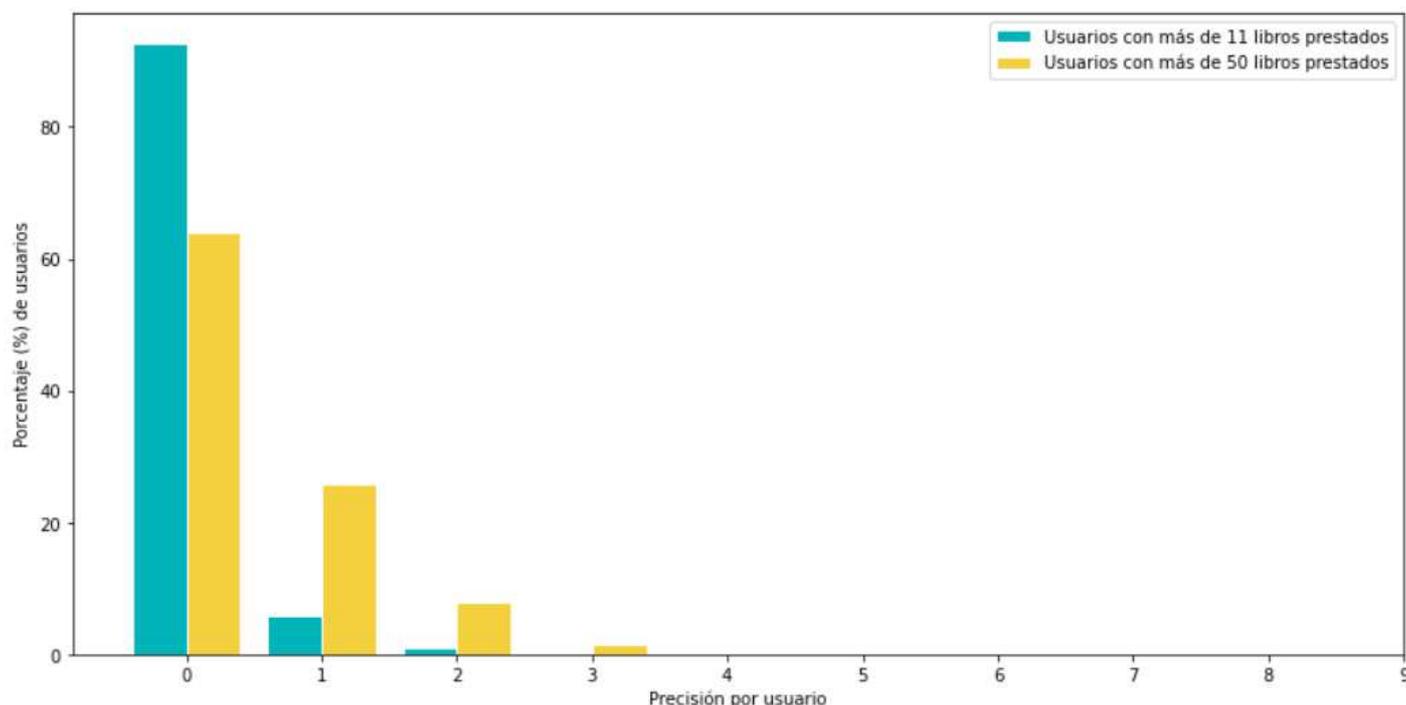


Figura 17: Distribución de porcentaje (%) de usuarios con respecto a la precisión del usuario para usuarios con al menos 11 libros prestados y con al menos 50 libros prestados

Teniendo en cuenta que una recomendación acertada es aquella en la que el libro recomendado coincide con alguno de los libros referencia, se observa que para ambas subpoblaciones de datos, los usuarios con 11 o más libros prestados (Figura 17 azul) o los usuarios con 50 o más libros prestados (Figura 17 amarillo), el **porcentaje de usuarios que no reciben ninguna recomendación acertada** es significativamente alto, **92,68%** y **64,01%** respectivamente. En concreto, la **precisión media de los usuarios**, es decir el número promedio de libros recomendados acertadamente es de **0,1** y **0,49**, respectivamente. Ambos valores se encuentran notablemente alejados de la cota mínima deseada a alcanzar por el modelo, cuyo objetivo es que en promedio el número de libros recomendados acertadamente sea igual o superior a 1.

Seguidamente, con el fin de evaluar si el modelo promueve algún tipo de discriminación se calculó el porcentaje de usuarios que tienen una precisión mayor a 1 para cada una de las subpoblaciones sensibles dadas, es decir, para cada uno de los subgrupos (por ejemplo para hombres y mujeres) se calculó el porcentaje de usuarios que tienen al menos una coincidencia entre los libros referencia y los recomendados, si el porcentaje difiere notablemente entre las diferentes subpoblaciones el modelo funcionará de manera desigual y por lo tanto promoverá una toma de decisiones no equitativa.

Para estudiar la equidad del modelo se valoraron las siguientes características como **variables sensibles a sufrir discriminación: Género del usuario, idioma del usuario, provincia donde se reserva el libro y la edad del usuario**. Debido a que el dataset `argus_top_5000_books.csv` solamente contiene las columnas `RECORD #(PATRON)` (código identificador del usuario), `key_id` (código identificador del libro) y `GOV DOC #` (código que indica la disciplina de conocimiento a la que pertenece el libro) y ninguna de variables asociadas a los usuarios, éstas fueron extraídas de los datasets `USUARIS1.txt`, `USUARIS2.txt`, `USUARIS3.txt`, `USUARIS4.txt`, `bibliografics1.txt`, `bibliografics2.txt` y

bibliografics3.txt provistos también por la Generalitat de Catalunya. En las siguientes secciones se presentarán los resultados y conclusiones obtenidas para cada una de las variables sensibles.

Evaluación de equidad por género de usuario

Con el fin de evaluar si el recomendador de libros ofrece un tratamiento equitativo para los usuarios hombres y mujeres se evaluó la precisión por usuario, el porcentaje de usuarios que reciben o no al menos una recomendación acertada y la precisión promedio para cada categoría de género. En las gráficas se ha incluido además la categoría “-“ que aparece en los datos e indica un género no determinado, pero ha sido ignorado en el estudio de la equidad puesto que se trata de una categoría en la que posiblemente están incluidos hombres y mujeres de manera indeterminada.

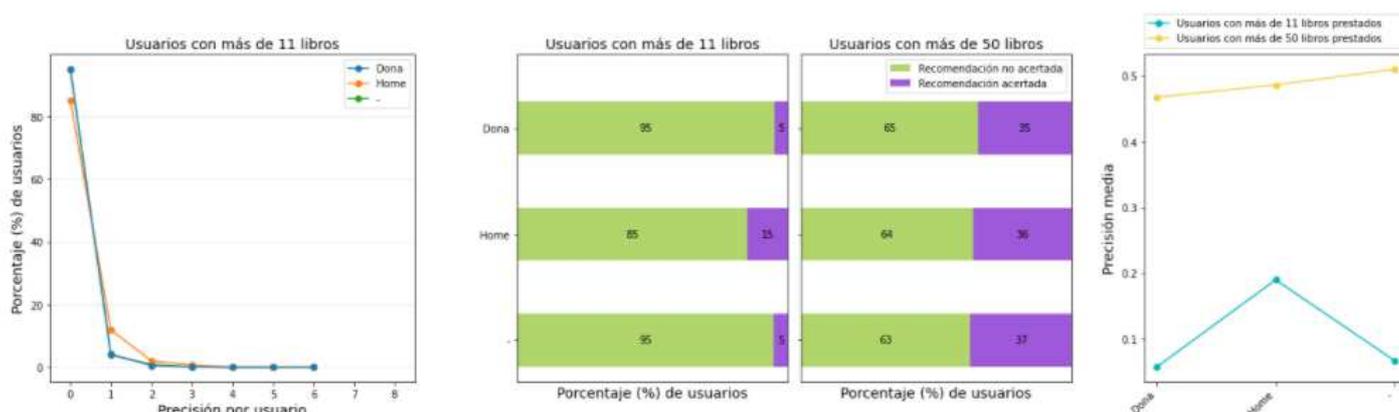


Figura 18: Análisis de la equidad del modelo recomendador de libros para cada posible género del usuario. Derecha: Distribución de porcentaje (%) de usuarios con respecto a la precisión para usuarios con al menos 11 libros prestados. Centro: Porcentaje (%) de usuarios con ninguna o al menos una recomendación acertada para usuarios con al menos 11 libros prestados (izquierda) o para usuarios con al menos 50 libros prestados (derecha). Derecha: Precisión media por género de usuario para usuarios con al menos 11 libros prestados (azul) o para usuarios con al menos 50 libros prestados (amarillo).

Como se observa en la gráfica de la izquierda en Figura 18, el **porcentaje de mujeres con una precisión nula** (Precision = 0) **es mayor que el porcentaje de hombres**, es decir **el porcentaje de mujeres que no reciben una recomendación válida o acertada es mayor**. Esto se debe principalmente a que hay más hombres que reciben solamente una recomendación acertada (Figura 18 izquierda, curva naranja vs. azul en Precision = 1) puesto que el porcentaje de hombres y mujeres con una precisión igual o mayor que 2 (Figura 18 izquierda, curva naranja vs. azul en Precision ≥ 2) es indistinto.

Esta diferencia entre hombres y mujeres se puede también confirmar en las gráficas centrales, donde a modo de simplificación por un lado se han unificado los usuarios con al menos una recomendación acertada (barras moradas, Precision ≥ 1) y por el otro el porcentaje de usuarios con ninguna recomendación acertada (barras verdes, Precision = 0). **Para todas las categorías de género el porcentaje de usuarios con ninguna recomendación acertada (barras verdes) es significativamente mayor que para los que tienen alguna recomendación acertada (barras moradas)**, sin embargo **esta diferencia se acrecienta sustancialmente para las mujeres**, donde el porcentaje de usuarias con una recomendación no acertada es tan solo del 95%, mientras que para el caso de los hombres es del 85% (Figura 18 central-izquierda). Esta diferencia en género se atenúa hasta ser prácticamente nula, cuando solamente tenemos en cuenta los usuarios con más de 50 libros prestados (el subconjunto de datos utilizado para ajustar el modelo), para mujeres es del 65% versus 64% para hombres (Figura 18 central-derecha). Sin embargo, es importante reseñar que el conjunto de usuarios con más de 50 libros prestados contiene una selección del 79,56% del grupo total de usuarios (4098 usuarios de 5151), mientras

él de más de 11 libros contiene el 98,70% del total (5083 usuarios de 5151). Por consiguiente, las conclusiones obtenidas con el subconjunto de usuarios con más de 50 libros son menos representativas y extrapolables a la población general, y por lo tanto las conclusiones generales serán las obtenidas en el subgrupo de más de 11 libros.

En consonancia con los resultados previamente comentados y teniendo en cuenta que la precisión está definida en un rango entre 0 (cuando ninguno de 10 libros de referencia han sido acertados por los 14 libros recomendados) y 10 (cuando los todos los libros de referencia han sido acertados por la recomendación), **para ambos géneros la precisión media por usuario es significativamente baja**, siendo **para los hombres sensiblemente mayor que para las mujeres**, 0,19 versus 0,06 (Figura 18 derecha curva azul).

Por lo tanto, los resultados obtenidos revelan que en base al porcentaje de recomendaciones acertadas (Figura 18 centro) y a la precisión media por usuario (Figura 18 derecha) para mujeres y hombres, se concluye que **el recomendador promueve un leve trato desigual para hombres y mujeres, siendo las recomendaciones a mujeres sensiblemente menos acertadas**.

Evaluación de equidad por edad de usuario

Durante el análisis exploratorio de los datos utilizados para entrenar el modelo se observó que no todos los intervalos de edad de los usuarios estaban igualmente representados, el intervalo de 10 a 15 años por ejemplo estaba especialmente sobrerrepresentado. Como consecuencia, al no haber sido entrenado por igual para todos los intervalos de edad, el modelo podría trabajar de manera desigual para cada uno de los intervalos. En la Figura 19 se muestra la precisión por usuario, el porcentaje de usuarios que reciben o no al menos una recomendación acertada y la precisión promedia para cada intervalo de edad. Con el fin de facilitar la comprensión y la visualización se han utilizado intervalos de edad más amplios que los utilizados para el análisis exploratorio y que agrupan los usuarios en 5 grandes grupos: de 2 a 12 años (infantil), de 12 a 20 años (adolescente), de 20 a 40 años (joven), de 40 a 60 años (adulto) y mayores de 60 años (seniors).

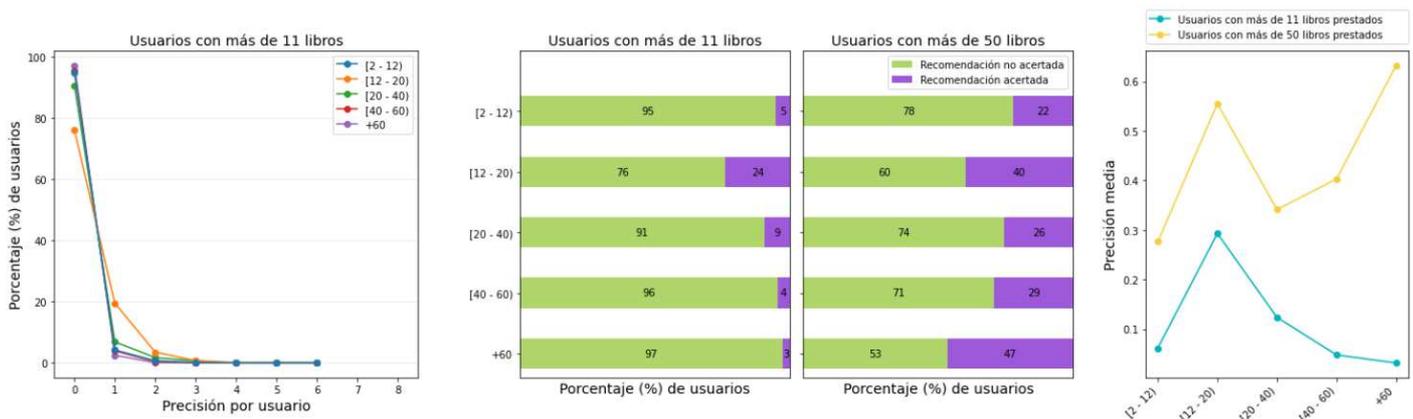


Figura 19: Análisis de la equidad del modelo recomendador libros para cada intervalo de edad del usuario. Derecha: Distribución de porcentaje (%) de usuarios con respecto a la precisión para usuarios con al menos 11 libros prestados. Centro: Porcentaje (%) de usuarios con ninguna o al menos una recomendación acertada para usuarios con al menos 11 libros prestados (izquierda) o para usuarios con al menos 50 libros prestados (derecha). Derecha: Precisión media por rango de edad de usuario para usuarios con al menos 11 libros prestados (azul) o para usuarios con al menos 50 libros prestados (amarillo).

La gráfica izquierda de la Figura 19 muestra que la **precisión para los usuarios con un intervalo de edad entre 12 y 20 años** es visiblemente **superior** debido a que para más de estos usuarios el recomendador ha acertado con una y dos

recomendaciones (Precision = 1 y Precision = 2 en Figura 19 izquierda, respectivamente), lo cual se traslada a un **mayor porcentaje de recomendaciones acertadas**, 24%, para estos usuarios (Figura 19 central-izquierda), mientras que para los demás intervalos ronda una media de 5,38%. Consecuentemente para estos usuarios su precisión media, 0,29, es también superior (Figura 19 central-derecha curva azul).

Por consiguiente, se concluye que el **recomendador de libros recomienda de manera desigual para los diferentes rangos de edad**, siendo los adolescentes (usuarios entre 12 y 20 años) los que mejores recomendaciones reciben.

Evaluación de equidad por idioma de usuario

A priori, se podría esperar que el idioma hablado por el usuario podría ser un variable importante a la hora de realizar una recomendación de un libro y que podría ser determinante para lograr una recomendación acertada. En consecuencia, se procedió a estudiar la precisión del modelo teniendo en cuenta esta variable, los resultados se muestran en la Figura 20. En varios de los usuarios su idioma estaba categorizado con un 0, lo cual significa que su idioma no ha sido determinado, por lo tanto a pesar de haber sido incluido en la visualización se ignorará la para evaluación de la equidad.

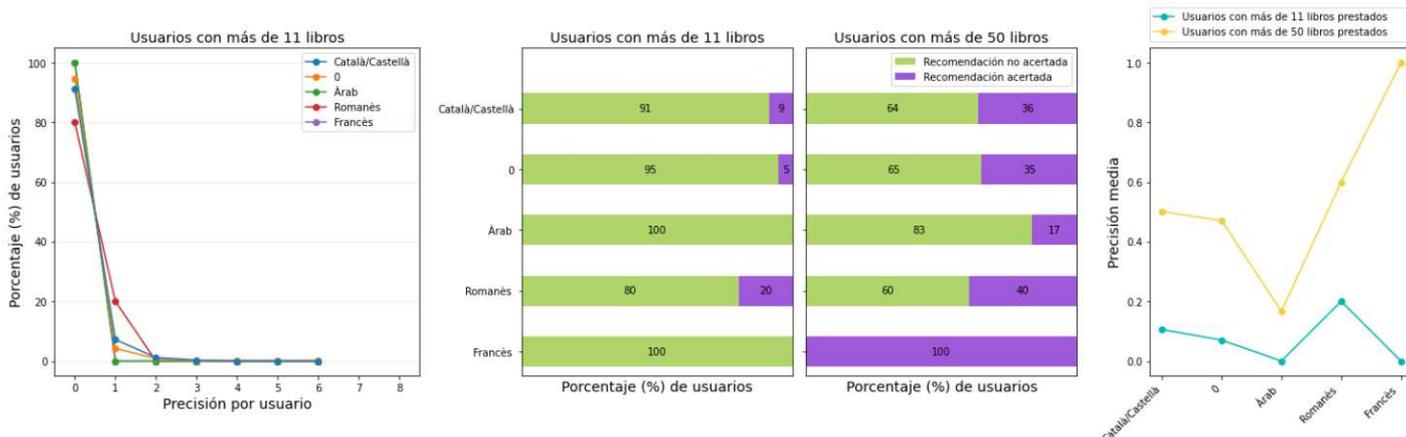


Figura 20: Análisis de la equidad del modelo recomendador libros para cada posible idioma usuario. Derecha: Distribución de porcentaje (%) de usuarios con respecto a la precisión para usuarios con al menos 11 libros prestados. Centro: Porcentaje (%) de usuarios con ninguna o al menos una recomendación acertada para usuarios con al menos 11 libros prestados (izquierda) o para usuarios con al menos 50 libros prestados (derecha). Derecha: Precisión media idioma de usuario para usuarios con al menos 11 libros prestados (azul) o para usuarios con al menos 50 libros prestados (amarillo).

Si siguiendo el mismo razonamiento desarrollado en las secciones Evaluación de equidad por género de usuario y Evaluación de equidad por edad de usuario, en la Figura 20 se observa que inesperadamente es para el idioma rumano donde el modelo se comporta mejor y obtiene tanto un mayor porcentaje de usuarios con recomendaciones acertadas (Figura 20 central-izquierda) como una mayor precisión media por usuario (Figura 20 izquierda curva azul), 20 % y 0,21 respectivamente. Sin embargo, debido que el porcentaje usuarios que hablan otro idioma que no sea catalán o castellano es considerablemente bajo, solamente el 0,6 % del total de usuarios, no se tienen datos suficientes y por lo tanto este análisis no es concluyente y no se puede deducir de manera inequívoca si el modelo es o no ecuánime para los diferentes usuarios teniendo en cuenta su idioma.

Evaluación de equidad por provincia de biblioteca

La provincia donde se encuentra la biblioteca puede ser utilizada como proxy de la provincia donde vive el usuario, que debido a la anonimización de datos es desconocida. Teniendo en cuenta que en el análisis exploratorio se observa que la mayoría de préstamos utilizados en el entrenamiento del modelo se ejecutan en Girona y Tarragona, podría ser que si los usuarios entre provincias difieran en comportamiento y que el modelo no se adecue correctamente para usuarios de ciertas provincias, es decir los hiperparámetros obtenidos durante el ajuste del modelo podrían depender de las provincias. Para comprobar si este es el caso, se realizó un estudio de precisión del modelo por provincia Figura 21.



Figura 21: Análisis de la equidad del recomendador para cada posible provincia donde se reserva el libro. Derecha: Distribución de porcentaje (%) de usuarios con respecto a la precisión para usuarios con al menos 11 libros prestados. Centro: Porcentaje (%) de usuarios con ninguna o al menos una recomendación acertada para usuarios con al menos 11 libros prestados (izquierda) o para usuarios con al menos 50 libros prestados (derecha). Derecha: Precisión media por provincia para usuarios con al menos 11 libros prestados (azul) o para usuarios con al menos 50 libros prestados (amarillo).

En la Figura 21 se manifiesta de manera evidente que el comportamiento del modelo es bastante similar para todas las provincias: la distribución de precisión por usuario (Figura 21 izquierda), el porcentaje de usuarios con recomendaciones acertadas (Figura 21 central) y la precisión promedio por usuario (Figura 21 derecha) apenas difieren entre las diferentes provincias. Quizás se puede apreciar una pequeña disminución para Barcelona pero el efecto es desdeñable, para Barcelona la precisión media es de 0 mientras que el promedio para las demás provincias es de 0.05, ambos valores diminutos.

Por consiguiente, se concluye que **no se ha detectado que el recomendador promueva un trato desigual para usuarios que reservan libros en diferentes provincias.**

4.2 Análisis equidad para autores/autoras

En el apartado 4.1 Análisis equidad para usuarios, se ha estudiado si el modelo ofrece recomendaciones de libros ecuanímenes para los diferentes posibles subgrupos de usuarios. En el presente apartado, sin embargo, se estudiará si las recomendaciones de libros son ecuanímenes desde el punto de vista del libro, es decir si se recomiendan por igual libros escritos por mujeres u hombres y si para ambos tipos de autores sus obras tienen la misma visibilidad y exposición a la hora de realizar la recomendación.

Para poder este análisis, inicialmente se extrajeron los códigos identificadores (RECORD #(BIBLIO)) y el nombre de los autores de todos los libros de las bibliotecas públicas de Catalunya. Para ello se utilizaron los archivos bibliográficos (bibliografics1.txt, bibliografics2.txt y bibliografics3.txt) provistos por la Generalitat de Catalunya.

Después, debido a que en ninguno de los datasets provistos por la Generalitat de Catalunya se encuentra especificado el género del autor y tras comprobar con fuentes de la misma Generalitat y bibliotecas que no existe una base de datos pública oficial en la que se detalle el género de los autores, se decidió determinar el género éstos mediante un algoritmo de machine learning llamado Gender-guesser (<https://pypi.org/project/gender-guesser/>). Este algoritmo determina el género de una persona a través del nombre de pila y para ello lo contrasta con un listado de más de 40.000 nombres de pila. Cada nombre queda categorizado en las categorías Home, Dona, Majoritàriament Home, Majoritàriament Dona, Andrògin (cuando el nombre se utiliza por igual para ambos géneros) y Desconegut (cuando se desconoce el género). Es importante enfatizar que **la precisión o exactitud de este tipo de algoritmos a pesar de ser alta no es del 100% por lo tanto los resultados obtenidos tendrán que considerarse con cautela.**

Una vez obtenido el género del autor por cada libro, es decir una tabla de equivalencia entre el identificador (RECORD #(BIBLIO)) de libro y género de autor, se evaluó la distribución por género de los libros incluidos en el archivo bibliográfico de la Generalitat de Catalunya (Figura 22).

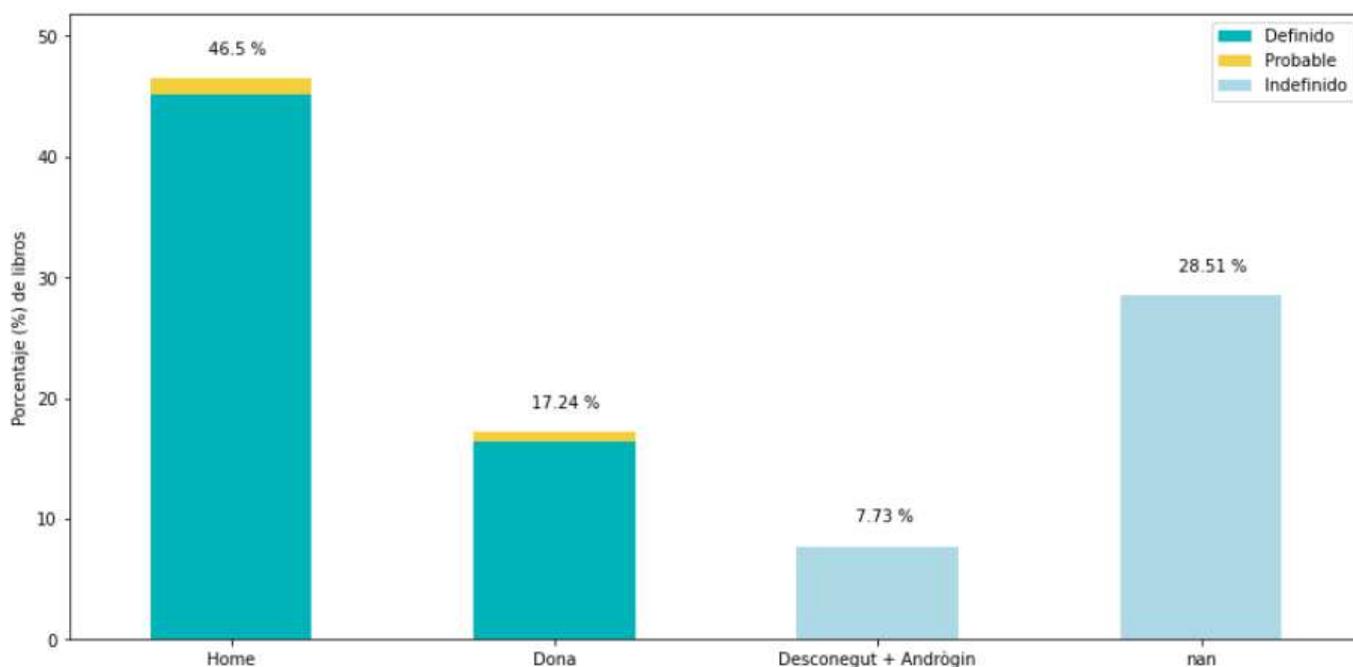


Figura 22: Distribución de porcentaje (%) por género del autor.

Aproximadamente la mitad de los libros que se albergan en las bibliotecas públicas catalanas están escritos por hombres, en concreto **el 46,5% de los libros han sido escritos por hombres y el 17,24% por mujeres**, el 33,24% restante no ha sido identificado (cuando el algoritmo considera el nombre andrógino o desconocido, Figura 22 tercera barra) o se encuentra indeterminado porque en el archivo bibliográfico para esos libros el campo autor no estaba completo (Figura 22 cuarta barra).

Paralelamente, para cada usuario incluido en el histórico de préstamos Argus provisto por la Generalitat de Catalunya se aplicó el modelo recomendador de libros y se obtuvieron los 14 libros recomendados por usuario. El género de los

autores de estos libros recomendados se determinó utilizando de nuevo la tabla de equivalencia identificador-género autor mencionada con anterioridad. Por lo tanto, para cada uno de los posibles 14 libros recomendados y para todos los usuarios que reciben el set de recomendación, quedó determinado que porcentaje de libros están escritos por mujeres u hombres (Figura 23 curvas grises).

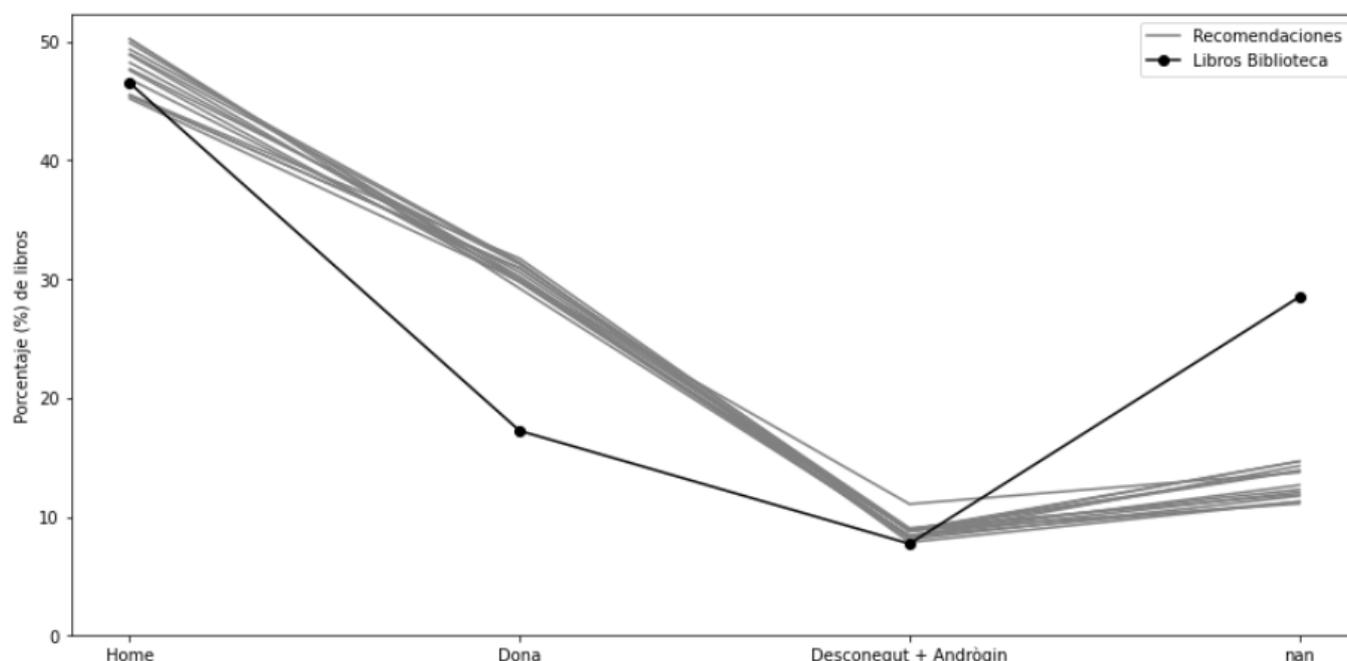


Figura 23: Distribución de porcentaje (%) por género del autor para todos los libros del archivo bibliográfico (curva negra) y los 14 libros recomendados (curvas grises).

Sorprendente se observa que para las 14 recomendaciones (Figura 23 curvas grises, cada curva representa una recomendación) el porcentaje de libros escritos por mujeres es mayor que el porcentaje de libros de autoras que contiene el archivo bibliográfico (Figura 23 curva negra versus curvas grises para la categoría Dona), un 39% versus el 17,24%, es decir **a pesar de haber menos libros escritos por mujeres en el archivo bibliográfico se recomiendan más a frecuentemente**. Sin embargo, **el porcentaje de recomendaciones de libros de autoras continúa estando significativamente por debajo del de autores**, en concreto es un **27.05% menor** (Figura 23 curvas grises para la categoría Dona versus categoría Home), de hecho el incremento para autoras viene dado por una bajada en recomendaciones de libros con autores sin determinar (Figura 23 curvas grises para la categoría nan), los autores se ven inalterados.

A la hora de hacer múltiples recomendaciones, como en el caso presente en el que se recomiendan 14 libros, **el orden o ranking en el que se dan estas recomendaciones es importante**, ya que dependiendo del puesto en el que se dé cierta recomendación tendrá más o menos exposición para con el usuario que recibe la recomendación: Los primeros puestos en un ranking tienen mayor exposición y por lo tanto mayor visibilidad de los últimos puestos. Considerando una caída de exposición estándar y comúnmente utilizada en la literatura previa (Singh & Joachims, 2018) de

$$\text{Exposición} = \frac{1}{\log(1 + j)}$$

donde j es la posición en el ranking, por ejemplo la exposición en segundo puesto del ranking baja un 36,90% con respecto al primer puesto y un 50% para el tercer puesto con respecto al primero.

En consecuencia, para valorar si el recomendador de libros está recomendando de manera ecuánime los libros escritos por mujeres y hombres, no solo cabe valorar el porcentaje de recomendaciones que se hacen de uno u otro género de autor, como ya hemos valorado inicialmente (Figura 23 curvas grises), sino además es necesario evaluar la exposición por género. Por ello, para cada ranking de 14 libros recomendados, se debe calcular la exposición que se da a las autoras con respecto a la exposición dada a los autores. Si la diferencia en exposición entre autoras y autores es positiva se considera que las autoras reciben una mayor visibilidad, si es negativa los autores tienen mayor visibilidad y si es nula ambos géneros tienen la misma visibilidad. En la Figura 24 se muestra la proporción de usuarios que reciben una diferencia de exposición negativa y positiva.

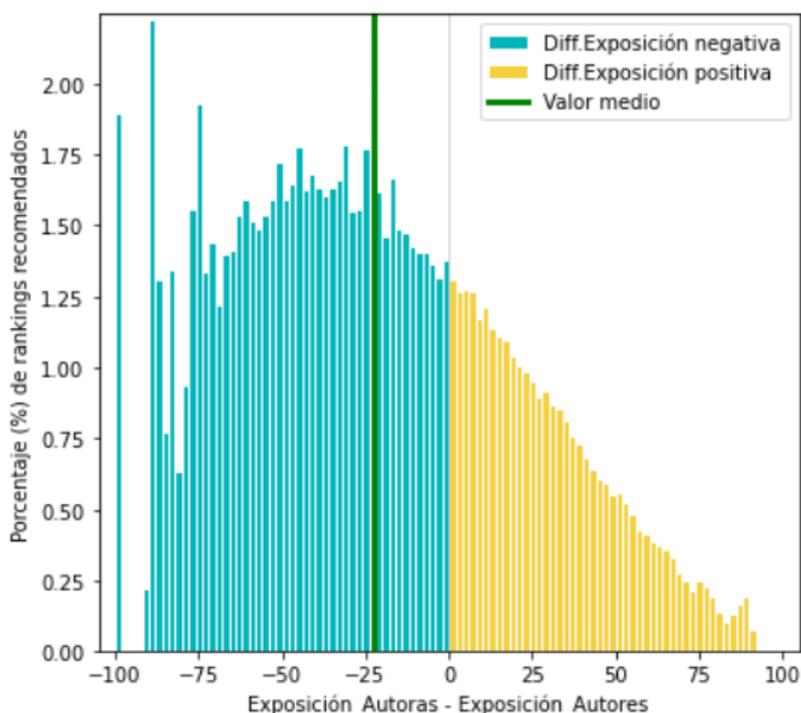


Figura 24: Porcentaje (%) de rankings recomendados versus diferencia en exposición entre autoras y autores. La fracción de la distribución señalada en azul tiene una diferencia de exposición negativa ($Exposición_Autoras < Exposición_Autores$) y la señalada en amarillo tiene una diferencia de exposición positiva ($Exposición_Autoras > Exposición_Autores$). La línea vertical verde indica la diferencia media en exposición para todos los rankings recomendados.

Como se observa para la gran mayoría de usuarios los rankings recomendados tienen una diferencia en exposición negativa, es decir los libros escritos por mujeres tienen una exposición menor que los escritos por hombres (Figura 24 distribución amarilla versus azul). En concreto, hasta en un 70,10 % de los ranking de recomendación generados por el modelo las autoras reciben una menor exposición (Figura 24 distribución azul), siendo la diferencia media de exposición un 22,48% menor para las autoras que para los autores (Figura 24 línea vertical verde).

Por consiguiente, se concluye que el recomendador de libros promueve un trato desigual para los libros escritos por mujeres y hombres, los libros escritos por mujeres se recomiendan menos que los escritos por hombres y su visibilidad global según el ranking de recomendación es menor.

5. Bibliografía

Singh, A., & Joachims, T. (2018). Fairness of Exposure in Rankings. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2219–2228.
<https://doi.org/10.1145/3219819.3220088>

