

UNIVERSIDAD POLITÉCNICA DE MADRID

E.T.S. DE INGENIERÍA DE SISTEMAS INFORMÁTICOS

PROYECTO FIN DE GRADO

GRADO EN INGENIERÍA DEL SOFTWARE

Impacto de los algoritmos de recomendación de las redes sociales en los jóvenes y adolescentes

Autor: Jorge Llorente Alguacil

Directora: Sandra Gómez Canaval

Madrid, Julio 2023



Jorge Llorente Alguacil

Impacto de los algoritmos de recomendación de las redes sociales en los jóvenes y adolescentes

, Sunday 16^o July, 2023


Directora: Sandra Gómez Canaval

E.T.S. de Ingeniería de Sistemas Informáticos

Campus Sur UPM, Carretera de Valencia (A-3), km. 7

28031, Madrid, España

Esta obra está bajo una licencia **Creative Commons «Atribución-CompartirIgual 4.0 Internacional»**.



Resumen

Cada vez los jóvenes y adolescentes acceden a las redes sociales en edades cada vez más tempranas. Estos acceden a este “mundo” en busca de un entretenimiento fácil y rápido, facilitado por todo el entretenimiento ofrecido así como por la información el contenido multimedia generado mucho del cual es dirigido gracias a los algoritmos de recomendación tan potentes que poseen estos servicios. Algoritmos que han generado problemas de adicción en 1 de cada 3 jóvenes y diversos problemas de salud mental incluyendo depresión, ansiedad y en los casos más extremos el suicidio.

Es por ello que, este Proyecto Fin de Grado (TFG) realiza un estudio acerca de esta problemática y estudia, desde un punto de vista práctico cómo funcionan los algoritmos de recomendación a un nivel más técnico mediante el uso de redes neuronales, identificando las principales técnicas utilizadas para ofrecer recomendaciones lo más precisas posibles. A su vez, se ha demostrado cómo esas técnicas pueden ser utilizadas o tener sesgos que interesan a empresas o personas que restan objetividad a dichos algoritmos, ya que pueden ser “manipulados” para que enseñe el contenido que quiere su creador.

Estos problemas que impactan en el uso de las redes sociales las hace responsables de problemas de adicción o incluso de problemas más graves como problemas de bienestar emocional y mental, la propagación de bulos y la polarización de la sociedad los cuales son aspectos que se han demostrado que las empresas intentan ocultar con tal de no tener perjuicios económicos, lo que demuestra la falta de ética de estas corporaciones. Es por esto que este TFG desea entablar un entorno de concienciación, crítica para generar un análisis que permita no olvidar los problemas subyacentes que acaecen en el uso poco éticos de algunos algoritmos inteligentes sobre las redes sociales.

Palabras clave: Adicción; Problemas de salud mental; Beneficios económicos; Falta de ética, Recomendadores, Redes Sociales

Abstract

Teenagers are increasingly accessing social networks at younger and younger ages. They access this “world” in search of quick and easy entertainment, facilitated by all the entertainment offered as well as by the information and multimedia content generated, much of which is directed thanks to the powerful recommendation algorithms that these services have. Algorithms have generated addiction problems in 1 out of every 3 young people and various mental health problems including depression, anxiety and in the most extreme cases suicide.

For this reason, this Final Degree Project (TFG) studies this problem and studies, from a practical point of view, how recommendation algorithms work at a more technical level through the use of neural networks, identifying the main techniques used to provide the most accurate recommendations possible. At the same time, it has been shown how these techniques can be used or have biases that are of interest to companies or individuals that detract from the objectivity of these algorithms, since they can be “manipulated” to show the content that their creator wants.

These problems that impact the use of social networks make them responsible for addiction problems or even more serious problems such as emotional wellbeing or mental health problems, the propagation of hoaxes and the polarization of society, which are aspects that companies have been shown to try to hide in order to avoid economic damage, demonstrating the lack of ethics of these corporations. It is for this reason that this TFG wishes to create an environment of awareness and criticism in order to generate an analysis that will allow us not to forget the underlying problems that occur in the unethical use of some intelligent algorithms on social networks.

Keywords: Addiction; Mental Health Problems; Economic benefit; Lack of ethics, Recommenders, Social Networking

Agradecimientos

Sin cuatro pilares fundamentales este trabajo no podría haber sido posible.

El primero de todos mi tutora Sandra, y sí, la tengo que poner en primer lugar. No solo como tutora, sino por la gran persona que es y la amistad que me llevo con ella. Reuniones larguísimas que siempre acababan desviándose a cotilleos, visitas sorpresa o temas más personales e íntimos. Gracias por no enfadarte a pesar de haber cambiado de tema 300 veces. Gracias por el apoyo y por el amor que me has brindado durante todo este proceso.

El segundo de ellos, mi mejor amiga Patricia. Que esté haciendo este tema tan “social” puede que en parte sea por su culpa. Siempre haciendo referencias a aspectos de la sociología y cómo, aunque sea muy poco, me ayuda a entender porqué actuamos como lo hacemos. También por el apoyo que me ha dado con el TFG, o como lo llamamos nosotros ***, y por estar ahí ante mis bajones, por animarme a continuar, por estar también mi día a día aunque no nos viésemos todo lo que quisiésemos y porque sin ella la experiencia en Madrid no hubiese sido lo mismo.

El tercero de ellos, mi hermana Nuria. Ella me ha enseñado a luchar por lo que queremos, aunque cueste. También me ha enseñado los valores que llevo hoy en día en mi mente y en mi corazón. Me ha enseñado a luchar por un mundo más justo y que pasito a pasito, las cosas se consiguen, aunque a veces no estemos en nuestro mejor momento.

Por último, y en mención especial a mi madre Ana. El esfuerzo que ha hecho para que yo pueda estar escribiendo estas palabras es inimaginable. También, si no fuese por los valores que me ha enseñado tampoco estaría haciendo este tema, y seguramente fuese otro completamente distinto. Y por último, sino fuese porque ella estudió un ciclo de informática, yo no estaría ni siquiera en esta Escuela.

Índice general

Índice general	i
Índice de figuras	ii
1 Introducción	1
1.1 Objetivos	2
1.2 Motivación y justificación	3
1.3 Estructura del documento	4
2 Las Redes Sociales	5
3 El “Algoritmo” en las redes sociales	13
3.1 Algoritmo de Instagram	13
3.2 Algoritmo de Twitter	15
3.3 Algoritmo de TikTok	16
4 Adicción a las redes sociales	18
4.1 Adicción a Instagram	19
4.2 Adicción a TikTok	22
5 Consecuencias de la adicción	24
5.1 Consecuencias de la adicción a Instagram	25
5.2 Consecuencias de la adicción a TikTok	27
6 Algoritmos de Recomendación	28
6.1 Tecnologías utilizadas	29
6.2 Propuesta de un algoritmo de recomendación	29
7 Objetividad de los Algoritmos de Recomendación	57

7.1	Conjunto de datos	57
7.2	Método Basado en Contenido	59
7.3	Filtrado Colaborativo	60
7.4	Filtrado Colaborativo con Deep Learning	61
7.5	Modelo Híbrido	62
7.6	Análisis de los resultados	63
8	Análisis de la situación actual	64
9	Aspectos legales, éticos y sociales e impacto	71
9.1	Aspectos legales, éticos y profesionales	71
9.2	Impacto social, económico y medioambiental	72
10	Conclusiones y trabajo futuro	74
10.1	Conclusiones	74
10.2	Trabajo futuro	76
	Bibliografía	77

Índice de figuras

2.1	Número de usuarios por red social. Fuente: Statista [10]	6
2.2	Número de usuarios por red social en España. Fuente: Statista [11]	6
2.3	Porcentaje de usuarios de redes sociales por rango de edad. Fuente: Statista [12]	7
2.4	Porcentaje de usuarios de la Generación Z por red social. Figura: Statista [13]	7
2.5	Numero de usuarios de Instagram en millones por año. Fuente: Statista [15]	9
2.6	Usuarios de Instagram por género. Fuente: Statista [16]	9
2.7	Estimación de usuarios en Twitter 2018-2027. Fuente: Statista [18]	10
2.8	Porcentaje de usuarios de Twitter por género. Fuente: Statista [19]	11
2.9	Número de usuarios de TikTok por año. Fuente: Statista [20]	12
2.10	Porcentaje de usuarios de TikTok por género. Fuente Statista [21]	12

6.1	Matriz Posts - Categorías	32
6.2	Matriz Usuarios - Posts	33
6.3	Características de los Posts. Fuente: Elaboración propia	34
6.4	Preferencias indicadas explícitamente por Belén Esteban. Fuente: Elaboración propia	35
6.5	Preferencias indicadas explícitamente por Belén Esteban y María Patiño. Fuente: Elaboración propia	36
6.6	Preferencias similares entre Belén Esteban y María Patiño. Fuente: Elaboración propia	37
6.7	Tabla Predicción Interacción - Test	39
6.8	Tabla que presenta los datos de entrenamiento para Filtrado Colaborativo	41
6.9	Arquitectura Red Neuronal - Filtrado Colaborativo en Texto	42
6.10	Arquitectura Red Neuronal - Filtrado Colaborativo	43
6.11	Entrenamiento - Filtrado Colaborativo	44
6.12	Tabla Predicción Test - Filtrado Colaborativo	44
6.13	Esquema de <i>Neural Collaborative Filtering</i> . Fuente: <i>Modern Recommendation Systems with Neural Networks</i> [38].	46
6.14	Arquitectura Red Neuronal Profunda - Filtrado Colaborativo en Texto	47
6.15	Arquitectura Red Neuronal Profunda - Filtrado Colaborativo	48
6.16	Entrenamiento - Filtrado Colaborativo Deep Learning	49
6.17	Tabla Predicción Test - Filtrado Colaborativo Deep Learning	49
6.18	Nuevos datos de entrenamiento	51
6.19	Nuevos datos de test	52
6.20	Arquitectura Simplificada Modelo Híbrido. Fuente: <i>Modern Recommendation Systems with Neural Networks</i> [38].	53
6.21	Arquitectura Red Neuronal Modelo Híbrido en Texto	53
6.22	Arquitectura Red Neuronal Modelo Híbrido	54
6.23	Entrenamiento - Modelo Híbrido	55
6.24	Tabla Predicción Test - Modelo Híbrido	55
7.1	Tabla de datos de entrenamiento modificada.	59
8.1	Tasa de Ingresos Hospitalarios de Mujeres Adolescentes entre los años 2001 y 2015 por cada 100, 000 mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]	65
8.2	Tasa de Ingresos Hospitalarios de Mujeres Pre-adolescentes entre los años 2001 y 2015 por cada 100, 000 mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]	65

8.3	Tasa de Suicidio en Mujeres Adolescentes entre los años 2000 y 2018 por cada millón de mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]	66
8.4	Tasa de Suicidio en Mujeres Pre-adolescentes entre los años 2000 y 2018 por cada millón de mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]	66
8.5	Captura de pantalla de un Tweet de una opinión sobre Irene Montero	68
8.6	Captura de pantalla de un Tweet del líder del partido político VOX.	68
8.7	Captura de pantalla del Tweet del periódico El País.	69

Índice de listados

6.1	Paquetes necesarios	29
6.2	Importación de los posts	31
6.3	Importación de los datos de los Usuarios	32
6.4	Generar Matriz Posts - Categorías	32
6.5	Selección de usuario y creación de vectores	37
6.6	Multiplicación de las matrices Post - Categorías con Usuarios - Posts	38
6.7	Tamaños de las matrices usadas	38
6.8	Estimación de ponderaciones	38
6.9	Evaluación de métricas Basado en Contenido	40
6.10	Resultados de la predicción Basado en Contenido	40
6.11	Código para preparar los datos de entrenamiento	41
6.12	Parámetros de entrenamiento Filtrado Colaborativo	43
6.13	Resultados Filtrado Colaborativo	45
6.14	Parámetros de entrenamiento Filtrado Colaborativo Neuronal	49
6.15	Resultados Filtrado Colaborativo Neuronal	50
6.16	Configuración Modelo Híbrido	50
6.17	Prueba del modelo	51
6.18	Parámetros de configuración del modelo híbrido	55
6.19	Resultados del modelo híbrido	56
7.1	Cambio en la interacción para la hipótesis H1	58
7.2	Escalado de datos	58
7.3	Resultados de test para la hipótesis 1	59
7.4	Filtrado colaborativo: parámetros configuración hipótesis 1	60
7.5	Resultados Filtrado Colaborativo H1	60
7.6	Configuración Filtrado Colaborativo con DL para H1	61
7.7	Resultados Filtrado Colaborativo con DL para H1	61
7.8	Configuración modelo híbrido H1	62

7.9	Resultados del modelo híbrido H1	62
-----	--	----

1.

Introducción

Las redes sociales se han convertido en una parte importante de la vida de las personas con independencia de la edad. En edades más tempranas e incluso en edades juveniles y en adultos jóvenes, éstas están sustituyendo las alternativas convencionales de comunicación (correo electrónico, llamadas telefónicas, reuniones personales, etc.). En algunos casos, la interacción vía redes sociales ha tenido efectos positivos en las personas. Por ejemplo, ha acercado las relaciones personales en circunstancias donde la distancia es un factor determinante, ha ayudado en una comunicación eficiente y en tiempo real, la auto-motivación, entre otras [1].

Para algunos individuos, sin embargo, y a pesar de las experiencias positivas observadas, muchos estudios derivados de serias investigaciones han demostrado que la actividad intensiva en las redes sociales puede contribuir al desarrollo de tendencias adictivas [1].

Estas adicciones generan problemas de comportamiento que pueden conducir a deterioros funcionales y psicológicos, sobre todo en la infancia y la adolescencia [2] [3]. Según un estudio publicado en [4] en Estados Unidos más del 90% de los menores de 18 años utilizan las redes sociales, y casi la mitad de estos jóvenes afirman estar conectados “casi constantemente” a las redes sociales [5].

Dado que la adolescencia es un periodo crítico para el desarrollo de las conductas sociales, y qué un entorno negativo en ello puede generar factores de riesgo en la salud emocional de los futuros adultos, la aparición de adicciones en el uso de las redes sociales en edades tempranas es un síntoma de una sociedad con problemas generales a nivel mundial [6]. Normalmente, estos problemas están relacionados con el aumento de la ansiedad social, la depresión, una mayor incidencia del trastorno por déficit de atención con hiperactividad, la soledad, ausencia de bienestar emocional, problemas familiares, entre otros [5] [7].

En la actualidad, en España es raro que haya personas que no tienen conexión a Internet o que no tengan redes sociales, y todavía más extraño cuando se habla de jóvenes y adolescentes. Con independencia del origen y el lugar de residencia, las redes sociales permiten a los jóvenes mante-

nerse al día de una manera sencilla y rápida, les abre la puerta a poder estar en contacto con sus amigos en cualquier momento y en cualquier lugar, o incluso de buscar entretenimiento más allá de la televisión, libros, películas o música. Ahora bien, la facilidad con la que se puede acceder a las redes sociales ha provocado que algunos jóvenes hagan un uso indebido de ella y se generen los problemas antes mencionados. Toda esta situación, llega a ser un elemento de alta preocupación entre padres, madres y educadores. Por otro lado, mucha de esta problemática puede llegar a surgir por el uso de estas redes sociales con un nivel confianza plena en este tipo de tecnologías. Esto agrava muchísimo más la situación porque el problema pasa desapercibido hasta momentos en los cuales ya es bastante complicado dar un paso atrás. Todo este contexto ha dado pie para que la sociedad se llegue a plantear la veracidad de los contenidos que se publican en las redes sociales y los objetivos que hay detrás de ellas, de sus promotores y de sus benefactores.

Este es el contexto en el cual se enmarca el desarrollo de este Trabajo Fin de Grado (TFG), el cual aborda desde una perspectiva teórico/práctica, un análisis de la situación actual con respecto a las redes sociales y su uso en la infancia y en la adolescencia de forma crítica y ética. Esto se aborda desde la implicación que tiene la Informática como el área en el cual se circunscriben estos desarrollos tecnológicos y cómo los últimos avances en algunas de sus áreas hacen pensar en el impacto que el uso de los métodos y herramientas desarrollados pueden, de forma indirecta o indirecta contribuir a este problema social.

1.1 Objetivos

Objetivo general

El objetivo general de este Trabajo Fin de Grado (a partir de ahora TFG) es doble. Por un lado, se pretende realizar un análisis crítico sobre la situación social del uso de las redes sociales, su impacto actual en la población más joven y las consecuencias que trae el uso abusivo de ellas en el desencadenamiento de problemas de adicción. Por otro lado, se pretende analizar el impacto que tienen los algoritmos de recomendación de las redes sociales en los jóvenes y adolescentes teniendo en cuenta los aspectos negativos que provocan en la vida de estos, dentro del contexto de la adicción o la aparición de trastornos en la salud mental de los jóvenes. También se pretende estudiar el funcionamiento de los algoritmos de recomendación y demostrar si estos pueden ser manipulados para que muestren la información que los creadores quieran.

Objetivos específicos

- **Objetivo específico primario:** Estudiar las consecuencias que tienen los algoritmos de recomendación en los jóvenes y adolescentes, observando los niveles o señales que provocan adicción a las redes sociales y si estos provocan que la calidad de vida de estas personas se reduzca, así como observar el comportamiento de las empresas ante las consecuencias que producen sus servicios.
- **Objetivo específico secundario:** Estudiar el funcionamiento de los algoritmos de recomendación mediante un ejemplo práctico, así como demostrar la capacidad de manipular dichos algoritmos de manera intencionada para poder cumplir determinados objetivos que persiga el creador de dicho algoritmo.

1.2 Motivación y justificación

El acceso a Internet ya es posible prácticamente desde que los niños son muy pequeños. Desde padres que le dan el móvil a sus hijos para que no “molesten” hasta las aulas virtuales que deben empezar a utilizar para poder realizar sus tareas escolares. Este acceso tan temprano a Internet hace que comiencen a descubrir las redes sociales cada vez más jóvenes.

La motivación que ha llevado al autor a hacer este TFG es la falta de educación que reciben los padres, educadores y los propios jóvenes sobre las consecuencias de un uso descontrolado de las redes sociales respecto a la salud mental de estos. La creencia nefasta de que el comportamiento en Internet y los actos que allí se producen no tienen consecuencias, o que, como ocurre detrás de una pantalla, no les puede afectar en la vida real, cuando en realidad cada vez más jóvenes están perdiendo la salud y la vida por ello.

En este contexto, se considera importante recalcar, visibilizar lo que más se pueda esta problemática. Es importante que la sociedad conozca los verdaderos riesgos que traen las redes sociales en un uso descontrolado y abusivo y vulnerabilidad que experimentan ya que en ellas se establecen algoritmos e información que persiguen un uso comercial o un uso privado anti-ético con el fin de manipular los intereses de los más vulnerables. Los objetivos que persiguen algunos de los algoritmos desplegados sobre las redes sociales, sobre todo los algoritmos de recomendación dejan entrever un problema de absoluta indefensión cuando los usuarios son adolescentes o niños/niñas. Esto no quiere decir que las redes sociales sean, lo que coloquialmente se diría como “un invento del diablo”, simplemente que en ellas se encuentran los fines más nobles o más turbios

encapsulados en una mareada de información que puede nublar la mente de los más vulnerables.

Las redes sociales pueden ser grandes herramientas o fuentes de entretenimiento, pero hay que conocer cuáles son sus aspectos negativos, para poder hacer un uso responsable de esta tecnología que está tan presente en la vida de casi todas las personas.

1.3 Estructura del documento

Esta memoria se estructura como se describe a continuación.

- **Capítulo 2:** Consiste en un breve repaso por la historia de las redes sociales, así como un detalle de los usuarios que poseen cada plataforma y sus perfiles.
- **Capítulo 3:** Consiste en una explicación general sobre cómo los algoritmos de las principales redes sociales califican el contenido a mostrar.
- **Capítulo 4:** Consiste en un detalle sobre la adicción a las redes sociales, qué lo provoca y estadísticas de adicción sobre Instagram y TikTok.
- **Capítulo 5:** Consiste en un detalle de las consecuencias de las adicciones de las redes sociales.
- **Capítulo 6:** Aborda la explicación técnica de cómo funcionan los algoritmos de recomendación con un ejemplo práctico mediante el uso de Redes Neuronales.
- **Capítulo 7:** Introduce aspectos claves para la demostración de la falta de objetividad de los algoritmos de recomendación en base a las intenciones del creador de dicho algoritmo.
- **Capítulo 8:** Analiza los problemas que han generado las redes sociales y sus algoritmos en la sociedad y cómo se intenta encubrir.
- **Capítulo 9:** Consiste en la descripción del Impacto social, medioambiental y económico que se relaciona con este proyecto.
- **Capítulo 10:** Comparte la descripción de las conclusiones del proyecto, así como de las limitaciones y trabajo a futuro.

2.

Las Redes Sociales

Con la popularización de Internet surgió el concepto de las redes sociales. En 1997 surgiría la primera red social conocida como *sixdegrees* y se continuaría con el famoso *MSN Messenger*, también conocido como *Windows Live Messenger*, *Windows Messenger*, entre otros nombre. Ésta sería ampliamente popular, sobre todo entre los *Millenials*. Posteriormente, se crearon otras plataformas como *Facebook* en Estados Unidos o *Tuenti* en España [8].

Todas estas redes al principio dependían principalmente de los ordenadores, por lo que en la movilidad solo se disponían de los mensajes de texto o SMS como manera de comunicarse por texto, o en su lugar, las llamadas telefónicas. Pero a partir de 2007 el primer *Smartphone*, el iPhone, como se conocen hoy en día, nacería y cambiaría el paradigma por completo [9].

Con la creciente popularización de los teléfonos inteligentes o Smartphones surgirían nuevas redes sociales como *WhatsApp*, *Instagram*, *Tinder* o *TikTok* (anteriormente, éste último era conocido como *Musical.ly*). La popularización de los nuevos teléfonos con capacidad de estar conectados todas las horas del día a Internet ha cambiado la manera de la que la sociedad consume contenido digital y cómo se expone al mundo digital, integrando cada vez más lo digital con lo tradicional [8].

En la siguiente figura (ver Figura 2.1) se puede observar que la red social con mayor número de usuarios es *Facebook* con 2.958 millones de usuarios. Es más, Meta, la compañía propietaria de Facebook, WhatsApp e Instagram suma más de 7 millones de usuarios. En el caso de la empresa ByteDance, propietaria de Tiktok y Douyin suma más de 1.700 millones de usuarios. En esta misma gráfica también se pueden observar muchas redes sociales que sólo están disponibles en China, debido a las restricciones del país.




Figura 2.1: Número de usuarios por red social. Fuente: Statista [10]

En 2021, según Statista, en España la red social más utilizada fue Facebook, siguiendo la tónica global. Como se puede observar en la Figura 2.2, desaparecen todas las redes sociales de origen chino debido a que éstas, como se ha mencionado anteriormente, sólo ofrecen sus servicios en el país asiático, a excepción de TikTok que es una versión internacional. Además, Meta es la compañía que más porcentaje de usuarios tiene en el país. También hay que destacar, que no se incluyen los servicios de mensajería ni de vídeo como YouTube.




Figura 2.2: Número de usuarios por red social en España. Fuente: Statista [11]

Si se analiza el uso de las redes sociales por rangos de edad en la Figura 2.3, se puede observar que la **Generación Z** son los principales usuarios de estas plataformas y por detrás de ellos estarían

los **Millennials**, debido a que estas generaciones han crecido junto a la aparición de Internet en el ámbito doméstico y la creación de las redes sociales.




Figura 2.3: Porcentaje de usuarios de redes sociales por rango de edad. Fuente: Statista [12]

Analizando la generación más joven que utiliza las redes sociales, es decir, la Generación Z, se puede obtener que la red social que más utilizan es Instagram, y WhatsApp, volviendo a tener Meta la mayor cuota de usuarios. En la gráfica mostrada en la Figura 2.4 también se puede observar que se utilizan redes sociales que no se habían mencionado antes, como BeReal, que es una nueva red social.




Figura 2.4: Porcentaje de usuarios de la Generación Z por red social. Fuente: Statista [13]

A través de los datos de la gráfica de Statista mostrada en la Figura 2.4, se puede observar que

entre los jóvenes las redes sociales más populares son Instagram, TikTok y Twitter, quitando los servicios de mensajería y los servicios de reproducción de contenidos. Todas estas redes sociales tienen métodos diferentes de utilizarse, pero todas ellas intentan utilizar las mismas fórmulas que las hacen tan populares. Ahora mismo, con el crecimiento que ha tenido TikTok, todas las redes sociales están intentando “tiktorizarse”.

Según Marketing4eCommerce [14], Instagram surgió en 2010 como una red social para amantes de la fotografía, pero con la peculiaridad de subir las fotografías desde el iPhone, gracias a los avances que estaban teniendo lugar en la fotografía móvil. En 2011 se crearían los [Hashtag](#) para etiquetar el tipo de fotografía que estábamos publicando.

En 2012, la aplicación se expandiría y llegaría a los usuarios de Android. Gracias a la popularidad de la que disfrutaba la red social, Facebook se interesó por ella y decidió comprarla. Debido a esta compra, a pesar de la independencia de Instagram respecto de Facebook, llegarían los anuncios a la aplicación.

A su vez en 2015 llegaría la funcionalidad de las [Stories](#) a Instagram, que consiste en subir una fotografía o vídeo durante 24 horas a pantalla completa. Este formato era una copia prácticamente idéntica al formato de la aplicación *Snapchat*, haciendo que muchos usuarios en España abandonasen la aplicación del fantasma para aglutinarse todos en Instagram. De nuevo, cogería prestado otro concepto, en este caso de Periscope (propiedad de Twitter), que consistía en la realización de vídeos en directo desde el móvil. Periscope cerraría finalmente en 2021 por un bajo número de usuarios.

En 2016, Instagram tuvo un rediseño muy grande con el que su logotipo y colores de marca cambiarían del azul y el histórico logo de la Polaroid, a un diseño completamente blanco y un logo de gradientes. Esto introduciría muchos cambios en la red social en adelante, ya que finalmente los fundadores de la red social abandonarían la compañía. En 2018, Instagram implementó IGTV, una función muy similar a Youtube pero con vídeos en vertical, y en 2020 añadiría la funcionalidad de los [Reels](#), debido al éxito que estaba teniendo Tiktok gracias a la pandemia de la COVID-19, la cuál es prácticamente un calco a Tiktok.

Respecto a los usuarios, según una estimación realizada por Statista, se puede obtener que el número de usuarios de la plataforma no deja de aumentar de manera constante, exceptuando en 2020, que el número de usuarios aumentaron en mayor medida que el resto de años se puede observar observar en la Figura 2.5.




Figura 2.5: Numero de usuarios de Instagram en millones por año. Fuente: Statista [15]

Respecto al género de los usuarios, en 2023, las personas que más utilizan Instagram son hombres, como se puede observar en la Figura 2.6, aunque a pesar de ello, no hay una diferencia notable respecto a las mujeres, por lo que no parece que el género sea un factor determinante a la hora de utilizar la red social.




Figura 2.6: Usuarios de Instagram por género. Fuente: Statista [16]

En 2023 Instagram dispone de múltiples funcionalidades, desde subir tus posts con fotografías, como originalmente se había creado, publicar Stories, vídeos de IGTV, Reels y ahora, una nueva funcionalidad, que consiste en notas que desaparecen a las 24 horas [14].

Otra de las redes sociales que utilizan los jóvenes principalmente es Twitter. De todas las que utilizan, es la más longeva, ya que fue creada en 2006, aunque no como una red social independiente, sino como un servicio interno de otro ya existente. Esta red social consiste en la publicación de texto de hasta 140 caracteres, aunque actualmente la limitación es hasta 280, convirtiéndose en los SMS públicos de Internet. En 2007, empezó a ganar gran popularidad, llegando a tener 70.000 [Tweets](#) al día [\[17\]](#). Lo que caracteriza a la red social es la inmediatez de los contenidos.

Según una estimación realizada por Statista en 2023, se puede obtener que la red social no ha dejado de crecer en lo que respecta al número de usuarios. Además, se puede ver en la [Figura 2.7](#) que el aumento de los usuarios se hace de una manera progresiva, sin observar grandes crecimientos en los últimos años.




Figura 2.7: Estimación de usuarios en Twitter 2018-2027. Fuente: Statista [\[18\]](#)

Si se analizan los usuarios según el género en la [Figura 2.8](#), se puede ver que es una red social que mayoritariamente usan hombres, destacando que en este caso la brecha entre ambos géneros es mayor que la que se ha visto en el caso de Instagram.




Figura 2.8: Porcentaje de usuarios de Twitter por género. Fuente: Statista [19]

Por otro lado, se tiene a la red social del momento, sobre todo entre jóvenes, TikTok. Esta app consiste en vídeos de corta duración (aunque ahora se han llegado a los 10 minutos de duración) que se pueden ver en bucle. Además la manera de la que se ven los vídeos es haciendo *scroll*, permitiendo poder ver un sinfín de vídeos ajustados a tus preferencias que el propio algoritmo de la aplicación es capaz de detectar. A su vez, permite insertar canciones o sonidos de otros creadores, lo cual ha llevado a la creación de modas y retos.

En 2016, en China, la empresa ByteDance sacó, a finales de ese mismo año, la aplicación en el mercado chino *A.me* que posteriormente pasaría a llamarse Douyin.

A partir de 2017, la empresa sacó la misma aplicación, pero para el mercado internacional conocida como TikTok. En 2017 TikTok adquirió Musical.ly, otra empresa china que destacaba por la creación de vídeos cortos con efectos y sonidos.

Pero al igual que Instagram, TikTok ha intentado renovarse añadiendo funciones que resultan bastante similares a las de otras redes sociales más populares. Por ejemplo, ahora en TikTok pueden subirse carruseles de fotos o *Stories*, como si de Instagram se tratase. También, intentando copiar a la nueva red social BeReal, TikTok lanzó una función conocida como *TikTok Now*, la cual consiste en publicar una fotografía cuando salta una notificación diaria en el terminal.

Según la estimación realizada en 2023 por Statista que se puede observar en la Figura 2.9, se puede apreciar el crecimiento que ha tenido TikTok en los últimos cinco años atrás, aumentando en este periodo más de mil millones de usuarios.





Figura 2.9: Número de usuarios de TikTok por año. Fuente: Statista [20]



• Hombres

• Mujeres

Figura 2.10: Porcentaje de usuarios de TikTok por género. Fuente Statista [21]

Respecto a diferencias entre género, se puede observar en la Figura 2.10 que, en este caso, TikTok es una red social utilizada mayoritariamente por mujeres (a diferencia de los casos anteriores), aunque la brecha entre géneros no es muy grande.

3. El “Algoritmo” en las redes sociales

Las redes sociales permiten consumir casi cualquier tipo de contenido desde comedia, fotos bonitas de gatitos, contenido de coches o hasta contenido político. Cada usuario es único y tiene diferentes preferencias, por lo que a la hora de recomendar contenido a un usuario se va a utilizar lo que coloquialmente se conoce como *el algoritmo*, y este es el encargado de escoger el contenido que vamos a visualizar dentro del amplio catálogo que tiene cada una de las redes sociales.

Cada red social tiene un algoritmo diferente, ya que según el tipo de contenido y los objetivos de cada compañía, se le da peso a un conjunto de características u a otras.

3.1 Algoritmo de Instagram

Al principio, la red social no disponía de un algoritmo, es decir, el contenido que iba saliendo en el [Feed de Instagram](#) del usuario y las Stories aparecían según la gente lo fuese publicando, a excepción de la sección “explora”, la cual sí disponía de un algoritmo de recomendación. Posteriormente, los algoritmos de recomendación se implementarían en la mayoría de las secciones de la red social.

Instagram tiene tres secciones diferentes y cada una de ellas dispone de su propio algoritmo de recomendación. Según el blog oficial de Instagram [\[22\]](#) y Hootsuite [\[23\]](#) estas tres secciones bien diferenciadas son:

- **Reels:** los Reels de Instagram, al igual que en TikTok, son contenido corto pero que intenta entretener al usuario. También, esta sección muestra bastante contenido de personas que

el usuario no sigue, a diferencia del Feed. Para mostrar los Reels instagram se basa en los siguientes parámetros:

- **La interacción del usuario:** Según las interacciones que haga el usuario con el contenido, y según los Hashtag en los que este categorizado el Reel, el algoritmo va a determinar los intereses del usuario, mostrando más este tipo de contenidos.
 - **Interacciones del contenido:** Otro factor que va a determinar el contenido que se muestra, es cómo ha interactuado el resto de usuarios con ese Reel, determinando si dicho vídeo es relevante para los miembros de la plataforma o no. Otro factor que influye en los contenidos que aparecen al usuario es la popularidad del creador del contenido.
 - **Calidad del contenido:** El contenido debe tener buena resolución y no debe tener marcas de agua. En caso contrario, la probabilidad de que el contenido se le muestre al usuario se reduce. También es importante la música o sonidos que se incluyan, intentando mostrar aquellos sonidos que en dicho momento sean más virales en la aplicación. Los contenidos que incluyen contenido político son menos mostrados.
- **Feed de Instagram y Stories:** En el blog de Instagram se indica que esta sección está dirigida a tus amigos y familiares, es decir, esas personas a las que más cercana es el usuario. El contenido que va a aparecer en el feed del usuario depende de los siguientes factores:
 - **El propio contenido:** de aquí se obtienen factores como su popularidad, la interacción que tiene, la duración, en caso de ser un vídeo, e incluso la localización de la publicación.
 - **Quién ha publicado el contenido:** Dependerá de la interacción que tengas en redes con el usuario y cuánto contenido haya publicado recientemente. También tendrá en cuenta, según las interacciones del usuario, como de interesante te parece el contenido.
 - **La actividad del usuario:** Según el tipo de publicaciones o Stories con las que interactúes la red social aprenderá sobre el contenido que puede interesarte y se lo va publicando al usuario.

Instagram introdujo cambios en el Feed, y es que ahora podrían aparecer Posts de personas que no sigues, pero te pueden parecer interesantes. Algo muy similar a lo que sucede con el Feed de explorar. Por ejemplo, en 2022 Instagram intentó impulsar su formato Reels, por lo que en el Feed era muy común que apareciesen Reels.

- **Sección explorar:** Esta sección sirve para recomendar al usuario contenido según aquel con el que ha interactuado anteriormente. Los contenidos que se muestren, serán en función de la probabilidad de que el contenido le guste al usuario o lo comparta. Para ello se siguen los siguientes criterios:
 - **Información sobre la publicación:** Es decir, cuántas interacciones tienen con ella los diferentes usuarios.
 - **Historial de interacciones con el usuario:** es decir, si un usuario no sigue a un determinado usuario, pero ve bastante contenido suyo, en la sección de explorar también aparecerá contenido de ese usuario. La sección explorar está más centrada en apariciones de cuentas nuevas.
 - **La actividad del usuario:** Según el contenido que se siga, y el contenido que vayas viendo en la sección de explorar, el algoritmo de Instagram aprenderá sobre tus gustos y te irá mostrando contenido similar.

3.2 Algoritmo de Twitter

Al comienzo de la red social, esta carecía de algoritmos de recomendación. Todo lo que veía el usuario era cronológico en el Inicio y las tendencias que aparecían eran según el número de tweets que se publicaban con un Hashtag en específico. Posteriormente en el Inicio y en el apartado de tendencias aparecerían nuevas secciones que mostrarían el contenido según los intereses de cada usuario en particular.

En la sección de Inicio, que es lo que podría equivaler al Feed de Instagram, se creó una nueva sección conocida como Tweets recientes, en la cual aparecerían los tweets cronológicamente, mientras que en el anterior “Inicio”, según Twitter, se muestran los Tweets según las cuentas y temas que sigues, como también Tweets recomendados. Acorde a Twitter [24], la manera que tiene la red social de identificar los tweets que pueden ser relevantes a para cada usuario depende en:

- La popularidad de los tweets y cuánta gente está interactuando con él.
- Contenido que puede ser relevante, creíble y seguro.
- Basado en los contenidos que sigue el usuario en la red social.

La empresa no ha detallado públicamente cómo puntúa los diferentes tweets según las características que se han mencionado anteriormente. Sin embargo, según Hootsuite [25], los algoritmos de Twitter tienen en cuenta los siguientes parámetros:

- **Actualidad:** Uno de los principales pilares de twitter era la instantaneidad de los hechos.
- **Relevancia:** Según la interacción con otros usuarios y los tweets que consuma un determinado usuario, la red social priorizará dichos contenidos. También la relevancia dependerá de la ubicación en la que te encuentres. Además, también tiene en cuenta el propio contenido que sube el usuario.
- **Popularidad:** Los tweets que se te muestren también dependerán en la popularidad de los usuarios, y como los usuarios a los que sigues interactúan con ellos.
- **Multimedia:** Los contenidos también se ordenarán según los que tipo de contenido se incluye en estos, ya sean GIFs, vídeos o fotografías.

Desde el cambio de directiva de Twitter, también el algoritmo está comenzando a priorizar a los usuarios que paguen la nueva suscripción de la plataforma.

3.3 Algoritmo de TikTok

TikTok con su algoritmo para su página de “Para ti” ha conseguido que la mayor parte de los usuarios pasen la mayoría del tiempo en esta parte de la web. A diferencia del resto de aplicaciones analizadas, aquí el algoritmo el usuario es el principal factor que la plataforma tiene en cuenta. Según Hootsuite [26], del usuario se tienen en cuenta los siguientes aspectos:

- Qué cuentas sigue el usuario.
- Comentarios en las publicaciones.
- Creadores y sonidos que el usuario ha ocultado.
- Vídeos que el usuario ha dado me gusta.
- Vídeos que el usuario ha comentado.
- Vídeos que el usuario ha añadido a favoritos.

- Vídeos que el usuario ha marcado como “No me interesa”.
- Vídeos que el usuario ha reportado.
- Cuánto tiempo ha estado un usuario viendo un vídeo.
- El contenido que sube el usuario.

Ahora bien, otro factor importante que se debe tener en cuenta respecto al algoritmo de TikTok, es cómo la plataforma es capaz de identificar el propio contenido, para a partir de los aspectos mencionados anteriormente, recomendar a los usuarios más contenidos del mismo tipo.

Los aspectos que tiene en cuenta respecto al propio contenido son [26]:

- Efectos utilizados.
- Subtítulos. (La plataforma los genera automáticamente a partir del contenido).
- Hashtags en la descripción del contenido.
- Sonidos utilizados.

Por último, para obtener resultados más precisos, TikTok también tiene en cuenta aspectos del dispositivo desde el que se está consumiendo el contenido, aunque no es el factor más influyente a la hora de recomendar el contenido.

Los aspectos que se tienen en cuenta son [26]:

- Contenido duplicado.
- Contenido que el usuario ya ha visto.
- Contenido que el algoritmo ha calificado como SPAM.
- Contenido que pueda provocar malestar al usuario.

4. Adicción a las redes sociales

La Dopamina, el principal químico relacionado con la adicción, se secreta en el cerebro cuando el ser humano experimenta una sensación de recompensa como encontrar comida, ropa o compañeros sexuales. La naturaleza diseñó el cerebro para sentir placer cuando estas experiencias ocurren, porque ellas permiten aumentar las probabilidades de supervivencia y de procreación. Otro factor que provoca que esta sustancia se segregue son las redes sociales, gracias a que estas son una fuente de entretenimiento para las personas. Ahora bien, el problema de esta sustancia es que es altamente adictiva y provoca que el cerebro cambie los comportamientos para poder seguir obteniendo sus recompensas [27].


Las redes sociales tienen dos factores determinantes [27]:

- Fácil acceso.
- Recompensa Rápida.

Estos dos factores también provocan un riesgo de adicción a la Dopamina, lo que resulta en que la sustancia se va haciendo más potente en el cerebro. Y todo esto también es influido por los colores vibrantes, el contenido que nunca se acaba, contenido que siempre va acorde con los gustos de la persona, etc. [27].

El ser humano por naturaleza es un ser social, lo que ha permitido la supervivencia de la especie durante millones de años. Esto es debido a que cada vez que una persona tiene una interacción social, su organismo produce Dopamina. Si se suman los factores anteriores al de las relaciones humanas, esta situación puede convertir a las redes sociales en una droga, porque estas redes no solo permiten consumir y crear contenido, sino que permite interactuar con muchas más personas, con las que no se podría interactuar sin la existencia de Internet [27].

Según Lanier Law Firm [28], de media, los usuarios pasan 2 horas y 27 minutos en las redes sociales. Por otro lado, según Headphones Addict, más de 210 millones de personas son adictas a las redes sociales. En el caso de los adolescentes, se estima que un 34% de los adolescentes estadounidenses son adictos a las redes sociales.



• No adictos

• Adictos

El problema a la adicción de las redes sociales llega cuando los usuarios ven estas plataformas para reducir su estrés, soledad o depresión. Al final, las redes sociales ofrecen recompensas que no se reciben en el mundo real, lo que provoca que los usuarios acaben enganchados a estas, provocando que los usuarios experimenten problemas como perder la relación sus amigos y familiares o perder la capacidad de concentración o rendimiento en el trabajo o en los estudios.

4.1 Adicción a Instagram

Para realizar el estudio de adicción a Instagram, se ha tenido en cuenta el estudio *Instagram addiction and the Big Five personality: The mediating role of self-linking* [29], en el que se menciona como la adicción a Internet se ha convertido en un tema muy popular entre los investigadores en los últimos tiempo. Este estudio es de los primeros que se realizaron sobre Instagram, ya que el resto de los estudios se habían desarrollado sobre otras redes sociales. En el estudio también mencionan que es importante este detalle debido a que cada red social tiene motivaciones y gratificaciones específicas.


Para realizar dicho estudio participaron 752 estudiantes universitarios para demostrar la adicción a Instagram según los rasgos de la personalidad. Para analizar la adicción a Instagram se utilizó la

Instagram Addiction Scale (IAS) que se compone de los siguientes elementos:

- ¿Con qué frecuencia prefieres la emoción de Instagram en lugar de estar con tus amigos íntimos?
- ¿Con qué frecuencia entablas nuevas relaciones con otros usuarios de Instagram?
- ¿Con qué frecuencia te pones a la defensiva o te muestras reservado cuando alguien te pregunta qué haces en Instagram?
- ¿Con qué frecuencia se resienten tus notas o tu trabajo escolar por la cantidad de tiempo que pasas en Instagram?
- ¿Con qué frecuencia chasqueas, gritas o te muestras molesto si alguien te molesta mientras estás en Instagram?
- ¿Con qué frecuencia intentas ocultar cuánto tiempo llevas en Instagram?
- ¿Con qué frecuencia eliges pasar más tiempo en Instagram que saliendo con otras personas?
- ¿Con qué frecuencia te sientes deprimido, malhumorado o nervioso cuando no estás en Instagram, que desaparece una vez que vuelves a Instagram?
- ¿Con qué frecuencia intentas reducir el tiempo que pasas en Instagram y fracasas?
- ¿Con qué frecuencia compruebas tu Instagram antes de hacer otra cosa?
- ¿Con qué frecuencia bloqueas los pensamientos perturbadores sobre tu vida con pensamientos tranquilizadores de Instagram?
- ¿Con qué frecuencia te encuentras anticipando cuándo volverás a entrar en Instagram?
- ¿Cuántas veces temes que la vida sin Instagram sería aburrida, vacía y sin alegría?
- ¿Con qué frecuencia pierdes el sueño por conectarte a Instagram a altas horas de la noche?
- ¿Cuántas veces te encuentras diciendo “sólo unos minutos más” cuando estás en Instagram?

En el estudio se obtuvo que el 66,5% de los participantes no eran usuarios de riesgo, un 26,5% tenían una ligera adicción a Instagram; un 6,1% eran usuarios moderadamente adictos y por último un 0,9% de los participantes era severamente adicto a Instagram. Respecto a estos datos

podemos obtener que un 33, 5% de los participantes eran usuarios adictos a Instagram, en mayor o menor medida. Esto implica que un tercio de los participantes al menos es adicto a Instagram.



• No adictos

• Adictos

Según el estudio *Associations Between Instagram Addiction, Academic Performance, Social Anxiety, Depression, and Life Satisfaction Among University Students* [30] los usuarios de Instagram vuelven a dicha red social porque allí pueden suplir sus necesidades de reconocimiento, sociales y de entretenimiento. En dicho estudio se revela que los usuarios tienden a usar Instagram para hacer directos, subir fotografías y vídeos para recibir “Likes” y comentarios como fuente de aprobación social, en este caso de sus seguidores.

Los usuarios para realizar estas actividades tienen que pasar más tiempo en Instagram, ya que no son meros consumidores de la red social, es decir, también crean el contenido y gastan más tiempo comprobando el feedback que recibe dicho contenido. En el estudio, una de las conclusiones principales es que las necesidades sociales están ampliamente relacionadas con la adicción a Instagram. Esto se puede afirmar ya que los jóvenes adultos están en una etapa en la que mantener sus amistades se vuelve más complicado, por lo que, principalmente las mantienen mediante las redes sociales. Lo anterior implica que los usuarios pasen más tiempo en la red social interactuando con otros usuarios, lo que puede provocar adicción a algunos usuarios. Además, los usuarios de la red social también utilizan la misma por entretenimiento, lo que implica que se utilice la red social para satisfacer las necesidades de entretenimiento.


4.2 Adicción a TikTok

Como ocurría con Instagram cuando empezó a popularizarse, TikTok no ha sido objeto de estudio tanto como otras redes sociales que también pueden fomentar un comportamiento compulsivo. La Universidad de Trinidad y Tobago realizó el estudio *“Needs affordance as a key factor in likelihood of problematic social media use: Validation, latent Profile analysis and comparison of TikTok and Facebook problematic use measures”* [31] para analizar el uso problemático de los estudiantes con las redes sociales.

En el estudio participaron 354 estudiantes universitarios, de los cuales 173 eran usuarios de TikTok. Para este estudio se utilizó la siguiente escala, en la que se miden los 6 elementos básicos de la adicción, según el autor:

- Tener pensamientos obsesivos sobre utilizar TikTok.
- Sentir el impulso de utilizar cada vez más TikTok.
- Usar TikTok para olvidarse de los problemas personales.
- Intentar reducir el uso de TikTok sin éxito.
- Sentirse molesto o inquieto cuando algo o alguien impide usar TikTok.
- Usar TikTok tanto que repercute negativamente en la escuela o en el trabajo.

En dicho estudio se concluyó que las personas que obtuvieron puntuaciones más altas es porque utilizan TikTok de manera intensa. Un 68, 2% son usuarios de riesgo, que son la mayoría de los usuarios, pero, un 25, 4% de los usuarios se categorizaron como usuarios de bajo riesgo y un 6, 4% de los usuarios fueron clasificados como usuarios de riesgo. Como resultado generales se obtiene que el 31, 8% de los usuarios son clasificados como usuarios de riesgo.



- No adictos

- Adictos

Es cierto que muchos usuarios de TikTok no utilizan la aplicación de una manera problemática, pero la adicción existe y no hay un pequeño número de usuarios que sean adictos. El problema reside es que la adicción a TikTok al final repercute en la vida diaria de los usuarios que son adictos. El estudio también recoge que un usuario puede ser adicto a TikTok, pero no tener un uso problemático en el resto de redes sociales.

Otro de los factores que ha hecho que aumente el número de personas adictas a las redes sociales en general, fue el confinamiento que hubo en 2020, que hizo que millones de personas solo pudiesen acceder a la vida social a través de las redes sociales. A partir de este año, se observa que el número de personas que tienen adicción de las redes sociales ha ido en aumento.

5. Consecuencias de la adicción

Según la Organización Mundial de la Salud la adicción es “una enfermedad física y psicoemocional que crea una dependencia o necesidad hacia una sustancia, actividad o relación. Se caracteriza por un conjunto de signos y síntomas, en los que se involucran factores biológicos, genéticos, psicológicos y sociales. Es una enfermedad progresiva y fatal, caracterizada por episodios continuos de descontrol, distorsiones del pensamiento y negación ante la enfermedad” [32].

Según Top Doctors [33], la sintomatología más común entre los adictos puede ser:

- Pérdida de control del uso, con episodios de uso compulsivo que afectan a la vida en general de la persona.
- Estado de ánimo triste.
- Irritabilidad.
- Deterioro de la calidad de vida.
- Negación.
- Ansiedad.
- Obsesión.
- Inquietud o preocupación excesiva.
- Insomnio.
- Sentimiento de culpabilidad.

La adicción está directamente asociada con el consumo de drogas, pero hay varios aspectos en la vida de las personas que pueden provocar que estas sean adictas, sin que sea necesario que estas

personas tomen sustancias. Se ha oído hablar de adicción a la comida o incluso adicción a las compras.

Una de las adicciones que más está comenzando a preocupar es la adicción a las TIC, y sobretodo la adicción a las redes sociales. Cabe destacar que cada adicción tiene una sintomatología diferente, es por ello por lo que en este trabajo se va a analizar las consecuencias que tiene la adicción a cada una de las redes sociales.

5.1 Consecuencias de la adicción a Instagram

El estudio *Associations Between Instagram Addiction, Academic Performance, Social Anxiety, Depression, and Life Satisfaction Among University Students* [30] se tuvieron en cuenta las siguientes hipótesis:

- H1. (a) Necesidades de reconocimiento. (b) Necesidades de información. (c) Necesidades sociales y (d) necesidades de entretenimiento, todas ellas están positivamente relacionadas a la adicción a Instagram entre los estudiantes.
- H2 (a). La adicción a Instagram está relacionada negativamente con un bajo rendimiento académico entre los estudiantes.
- H2 (b). Un buen rendimiento académico está asociado positivamente con un mayor nivel de satisfacción de vida entre los estudiantes.
- H3 (a). La adicción a Instagram está relacionada positivamente con la [Ansiedad social](#) entre los estudiantes.
- H3 (b). La ansiedad social está asociada negativamente con un menor nivel de satisfacción de vida entre los estudiantes.
- H4 (a). La adicción a Instagram está positivamente relacionada a tener depresión entre los estudiantes.
- H4 (b). La depresión está asociada positivamente con un menor nivel de satisfacción de vida entre los estudiantes.
- H5 (a). La actividad física modera negativamente la asociación entre las necesidades de reconocimiento y la adicción a Instagram.

- H5 (b). La actividad física modera negativamente la asociación entre las necesidades de información y la adicción a Instagram.
- H5 (c). La actividad física modera negativamente la asociación entre las necesidades sociales y la adicción a Instagram.
- H5 (d). La actividad física modera negativamente la asociación entre las necesidades de entretenimiento y la adicción a Instagram.

En este TFG sólo se tendrán en cuenta las hipótesis H2, H3 y H4. del estudio. Para dicho estudio participaron 364 estudiantes universitarios estadounidenses.

Finalmente, en el estudio se obtuvo que la adicción a Instagram está asociada a tener un menor rendimiento académico. Esto es debido a que los usuarios reducen su tiempo de estudio para hacer otras actividades en la red social, ya sea como ver contenido, relacionarse con otros usuarios, etc. Además, esto provoca que al reducir el rendimiento académico, también se reducía el nivel de satisfacción de vida de los estudiantes, ya que el rendimiento en los estudios es uno de los dominios más críticos en sus vidas.

Respecto a la relación entre la ansiedad social y la adicción a Instagram, en el estudio también se obtuvo que la asociación es positiva. Además la ansiedad también provoca que el nivel de satisfacción de vida de los estudiantes se reduzca. Al final Instagram ofrece gran variedad de información de muchas personas que resultan en una comparación social. El problema también se encuentra en que los usuarios solo tienden a subir los aspectos positivos de su vida, lo que provoca que los usuarios se comparen únicamente a la alza, lo que hace que algunas personas se sientan incompetentes. A esta comparación se le suma el número de *likes*, comentarios e interacciones que tiene el contenido que sube un usuario. En el estudio también se menciona que Instagram está asociado a que a algunas mujeres no les guste su físico, debido a las comparaciones de los cuerpos que se pueden hacer en Instagram, por lo ya mencionado anteriormente.

La relación entre la adicción a Instagram y la depresión también es positiva, además de dicha relación también es positiva para otras redes sociales. La depresión puede explicarse por la comparación social y por la envidia. Además, volviendo a las comparaciones, los usuarios pueden sentirse deprimidos si sienten que no han conseguido “ganar” en la competición de poder y atraktividad, lo que puede hacer que surjan inseguridades en los usuarios sobre lo que van a pensar los demás. Además, en el estudio se confirma que la depresión está asociada a un menor nivel de satisfacción de vida.

5.2 Consecuencias de la adicción a TikTok

En el estudio *Research on Adolescents Regarding the Indirect Effect of Depression, Anxiety, and Stress between TikTok Use Disorder and Memory Loss* [34], que se ha utilizado como referencia, participaron 3036 estudiantes chinos de secundaria, los cuales respondieron un cuestionario de 21 preguntas de 0 a 3. En dicho estudio se analizó el efecto de la depresión, la ansiedad y el estrés mediante la adicción a TikTok y la pérdida de memoria. Para llevar a cabo dicho estudio se llevaron a cabo las siguientes hipótesis:

- H1. La adicción a TikTok (TikTok Use Disorder, TTUD) está asociado a la pérdida de memoria.
- H2. La adicción a TikTok (TTUD) está asociada positivamente a la depresión, ansiedad y estrés.
- H3. La depresión, la ansiedad y el estrés están asociados a la pérdida de memoria.
- H4. La depresión, ansiedad y el estrés tienen un efecto entre la adicción a TikTok (TTUD) y la pérdida de memoria.

En el estudio se obtuvo que la adicción a TikTok (TTUD) está relacionada positivamente con la pérdida de memoria, siendo independiente del género. También confirma que la adicción a TikTok está positivamente relacionada con la depresión, y esta con la pérdida de memoria.

Otro aspecto a tener en cuenta es que TikTok está reduciendo la capacidad de atención de sus usuarios [35], debido a la rapidez de los vídeos, ya que estos son bastante cortos, siendo la mayoría como mucho de un minuto. Estos vídeos tan cortos están provocando que los usuarios tengan que prestar una cantidad menor de tiempo de atención, por lo que para tareas más largas, es más complicado mantener la atención.

Por ejemplo, la estudiante Audrey Mekler en su trabajo *The Effects of TikTok Use on College Student Learning* [36] obtuvo que los estudiantes universitarios en clase se distraían con TikTok o cuando debían completar tareas relacionadas con la universidad, a medida que pasaban más tiempo en la plataforma.

6. Algoritmos de Recomendación

En la sección 3 se ha visto que las redes sociales disponen de mecanismos para recomendar a los usuarios diferente tipo de contenido. Toda esta información está disponible en las páginas oficiales de cada servicio o bien en plataformas que se dedican al marketing digital. Sin embargo, en ninguna de ellas se trata qué es un algoritmo de recomendación ni cómo funcionan desde un punto de vista técnico. Es por ello, por lo que en este TFG abordará en este capítulo estos dos temas de forma que se explique en detalle este tipo de algoritmos y cómo funcionan estos a través de un ejemplo práctico bien acotado.

Un algoritmo de recomendación se caracteriza por ser un modelo que genera recomendaciones sobre un cierto objeto de estudio, como pueden ser productos, películas, canciones, etc. Dichas recomendaciones se obtienen a través de las preferencias y opiniones dadas por los diferentes usuarios de una aplicación [37].

Según el sitio web Quanam [37] hacer recomendaciones tiene ciertas ventajas como:

- Ahorrar tiempo a los usuarios a la hora de seleccionar productos, servicios, etc.
- Personalizar la experiencia del usuario.
- Tener mayor conocimiento sobre las preferencias de los usuarios.

Para llevar a cabo este TFG se ha tenido en cuenta el artículo “*Modern Recommendation Systems with Neural Networks*” [38] de Towards Data Science en el que se explica, mediante un ejemplo práctico, cómo crear un sistema de recomendación con redes neuronales usando Python y TensorFlow.

6.1 Tecnologías utilizadas

Las redes neuronales pueden ser implementaciones tanto de hardware como software que imitan las capacidades computacionales de sistemas biológicos interconectando múltiples neuronas. Dichas neuronas intentan simular el comportamiento de una neurona biológica. Cada neurona toma la información que le dan otras neuronas, se llevan a cabo algunas operaciones y el resultado se lo pasa a otras neuronas [39].

Un aspecto importante sobre las redes neuronales, es que éstas son capaces de generalizar, de tal manera que una vez una red neuronal ya ha aprendido, esta es capaz de aplicar la abstracción obtenida mediante métodos estadísticos para realizar tareas como la clasificación o identificación de objetos, la predicción o la generación de nueva información. Además, éstas son muy flexibles, lo que permite adaptarlas sin necesidad de que sean reprogramadas o re-entrenadas [39].

Para llevar a cabo el sistema de recomendación basado en redes neuronales que se utilizará de ejemplo práctico para este TFG se va a utilizar TensorFlow, que es una biblioteca de código abierto y desarrollada por Google para llevar a cabo aprendizaje automático profundo [40]. Para ejecutar el código se utilizará Google Colaboratory o Colab, que es un framework que permite ejecutar código Python desde cualquier navegador utilizando la capacidad de computo que ofrece Google para este servicio [41].

6.2 Propuesta de un algoritmo de recomendación

En esta sección se describe, desarrolla y explica la implementación de un algoritmo de recomendación que usa un conjunto de datos sintético. Con el contenido que se introduce a partir de este punto en este Capítulo se busca mostrar las bondades y facilidades que ofrecen estos algoritmos para mostrar un contenido autodirigido y sesgado. De esta forma, se pretende conseguir el objetivo segundo propuesto por este TFG.

Preparación del entorno

Para llevar a cabo el desarrollo del sistema de recomendación se requieren los paquetes disponibles en el Listado 6.1.

Listado 6.1: Paquetes necesarios

```
## para procesar los datos
import pandas as pd
import numpy as np
import re
from datetime import datetime

## for plotting
import matplotlib.pyplot as plt
import seaborn as sns

## for machine learning
from sklearn import metrics, preprocessing

## for deep learning
from tensorflow.keras import models, layers, utils #(2.6.0)
```

Conjunto de datos

Después de configurar el entorno de programación con las herramientas necesarias, se requiere importar los datos a utilizar para entrenar y probar la red neuronal profunda que se va a modelar.

Para este TFG se ha tomado la decisión de utilizar un conjunto de datos (*dataset*) sintético, dada la imposibilidad de encontrar uno que se ajuste a las necesidades del desarrollo práctico que se quiere conseguir. A este aspecto se le suma la normativa europea que obliga a que los datos de los usuarios de las redes sociales deben estar protegidos [42].

Un dataset sintético es un conjunto de datos que se genera de forma automática siguiendo un patrón estadístico concreto, en muchos casos, siguiendo distribuciones reales y que puede ser generado de forma aleatoria. Este tipo de conjunto de datos es útil cuando se requieren datos similares a los reales pero que no sean datos personales para no vulnerar la privacidad de los datos. También se utilizan en técnicas de aumentación de datos o para realizar simulaciones cuando no se disponen de conjuntos de datos reales.

En este contexto, se ha definido y creado dataset sintético a medida para el desarrollo del siste-

ma de recomendación de este TFG. Dicho dataset contiene 9999 posts y 49999 interacciones de usuarios con dichos posts. Cada interacción contiene la fecha y hora en la que se produjo entre el 14 de junio de 2022 y el 14 de junio de 2023. Dichas interacciones se han definido para que sean de 3 tipos diferentes:

- **Me gusta.** Valor: 1 punto
- **No me gusta.** Valor: -1 punto
- **Comentario.** Valor: 3 puntos

Una vez importados los paquetes necesarios y generado el dataset, ya se pueden importar los datos de éste teniendo en cuenta cuál es nuestro objetivo y cuál es el contexto que se persigue con el sistema de recomendación:

- **Objetivo.** Variable “Interaction”.
- **Contexto.** La hora a la que el usuario interactúa.

La importación de los post se realiza como se muestra en el Listado 6.2.

Listado 6.2: Importación de los posts

```
# Importamos los posts
dtf_posts = pd.read_excel("data_socialnetworking.xlsx", sheet_name="posts")
```

Para el algoritmo de recomendación que se va a realizar en este TFG, es importante la hora a la que se realiza la interacción, porque dependiendo de dicha hora, las recomendaciones pueden variar. Esto es debido a que los usuarios pueden ver distintos tipos de contenidos cuando está trabajando, mientras que cuando está en su tiempo tiempo libre prefiere ver otro tipo de contenido.

Por ese motivo, se va a definir cuándo un usuario interactúa después de las horas de trabajo y durante las horas de trabajo, para determinar cuándo los usuarios están en su tiempo libre. Para ello, se importarán los datos de los usuarios del dataset tal y como se especifica en el Listado 6.3.




Figura 6.1: Matriz Posts - Categorías

Listado 6.3: Importación de los datos de los Usuarios

```
# Importamos las interacciones de los usuarios
dtf_users = pd.read_excel("data_socialnetworking.xlsx", sheet_name="
    interactions")

dtf_users["Timestamp"] = dtf_users["Timestamp"].apply(lambda x: datetime.
    fromtimestamp(x))
dtf_users["Afterwork"] = dtf_users["Timestamp"].apply(lambda x: 0 if 6<
    int(x.strftime("%H"))<20 else 1)
dtf_users["Weekend"] = dtf_users["Timestamp"].apply(lambda x: 1 if x.
    weekday() in [5,6] else 0)
```

Como se indica en el artículo “*Modern Recommendation Systems with Neural Networks*” [38], se va a obtener la matriz Posts - Categorías para entender, de una manera más sencilla, qué elementos poseen cierta característica, tal y como se puede apreciar en la Figura 6.1 y en el Listado 6.4.

Listado 6.4: Generar Matriz Posts - Categorías

```
fig, ax = plt.subplots(figsize=(20,5))
sns.heatmap(dtf_posts==0, vmin=0, vmax=1, cbar=False, ax=ax).set_title("
    Posts x Categorías")
```

También se puede obtener la matriz Usuario - Posts en la Figura 6.2. En este caso, se puede observar

con qué posts han interactuado cada uno de los usuarios que aparecen en el dataset.




Figura 6.2: Matriz Usuarios - Posts

Como se puede observar la dispersión en la Matriz Posts - Categorías de la Figura 6.1 es bastante grande, pero en el caso de la dispersión de la Matriz Usuarios - Posts, de la Figura 6.2 se puede observar que su dispersión es bastante mayor.

Por último, antes de empezar a definir la arquitectura de la red neuronal, es importante destacar la necesidad de separar los datos que se van a utilizar para entrenar la red neuronal, y los datos que se van a utilizar para realizar el *testing*. Para ello, se separará un 80% de los datos para el entrenamiento, y un 20% de los datos para el test.

Técnicas de diseño

A la hora de realizar recomendaciones es importante la experiencia, es decir, es necesario conocer las preferencias de los usuarios para poder realizar las recomendaciones más acertadas posibles y poder aplicarlas a nuevos usuarios que utilicen las redes sociales. En función del número de usuarios y productos, posts en el caso de este TFG, que se dispongan se podrán aplicar diferentes técnicas.

Problema del folio en blanco

En el caso de que una red social haya abierto recientemente, esta no dispone de los datos necesarios para saber cuáles son las preferencias de sus usuarios, ya que no se dispone de las experiencias de otros usuarios. Esto es lo que en este TFG vamos a llamar como el problema del folio en blanco.

Para solucionar este problema, se hará un enfoque basado en el conocimiento, es decir, al crear un perfil un usuario, se le preguntará acerca de sus preferencias, a partir de una lista genérica. A


	#Perro	#Gato	#Conejo
		X	
	X	X	
			X

Figura 6.3: Características de los Posts. Fuente: Elaboración propia

partir de ese enfoque, una vez un mayor número de usuarios se suscriban al servicio, ya se podrán utilizar técnicas más avanzadas.

A continuación se explicarán de forma detallada las diferentes técnicas existentes para la generación de las recomendaciones realizadas por estos algoritmos.

Filtro basado en el contenido

Según la web de aprendizaje de [Machine Learning](#) de Google, “el filtrado basado en el contenido usa funciones para recomendar otros elementos de forma similar a lo que le gusta al usuario en función de sus acciones anteriores o comentarios explícitos” [43].

Para aplicar esta técnica se debe tener en cuenta las características que tienen los productos, en nuestro caso los posts, es decir, el usuario está calificando las características que tienen esos posts, no al post en sí mismo.

Ejemplo: A la usuaria @belenesteban le gusta el post de gatitos, y en otro post aparecen perros y gatos, por lo que la usuaria @belenesteban tiene grandes probabilidades de que le guste el post de perros y gatos, porque le ha gustado el post de gatos.

	#Perro	#Gato	#Conejo
		X	

Figura 6.4: Preferencias indicadas explícitamente por Belén Esteban. Fuente: Elaboración propia

Filtrado colaborativo

Según Cleverdata [44], el método de filtrado colaborativo consiste en analizar las interacciones que ha hecho un usuario anteriormente y sus preferencias, y posteriormente busca usuarios que sean similares a este y que han tomado decisiones similares. Es decir, si a un usuario le gustan ciertos posts, a un usuario similar a este habrá grandes probabilidades de que le gusten los mismos posts.

Ejemplo: A la usuaria @belenesteban le gustan los posts de la boda de Anabel Pantoja y el post de Belén Esteban con su gazpacho. En cambio a la usuaria @mariapatiño le gustan los post de Lydia Lozano, el de Chelo García Cortés y también el de la boda de Anabel Pantoja.

Como se puede observar en la Figura 6.5 a Belen Esteban y a María Patiño les gusta el post de la boda de Anabel Pantoja, por lo que existen probabilidades de que ambas usuarias tengan preferencias similares. Por ese mismo motivo, mediante el método de Filtrado Colaborativo, al establecer que ambas usuarias tienen preferencias similares, se les pueden recomendar posts similares. En el caso de Belén Esteban se le recomiendan el post de Lydia Lozano y el de Chelo García Cortés, mientras que a María Patiño se le recomienda el post de Belén Esteban con su gazpacho.

Según el artículo “Modern Recommendation Systems with Neural Networks” [38] existen dos grupos en los que los métodos de filtrado colaborativo se pueden clasificar. Estos son:

- **Basados en memoria.** Encuentra usuarios con métricas de correlación, [Análisis de grupos](#) y [Similitud de coseno](#)
- **Basados en modelos.** Predice cómo los usuarios van a valorar cierto *post* aplicando aprendizaje automático supervisado y [Factorización de matrices](#).




Figura 6.5: Preferencias indicadas explícitamente por Belén Esteban y María Patiño. Fuente: Elaboración propia

Modelo híbrido

Según el artículo “*Modern Recommendation Systems with Neural Networks* [38], los modelos híbridos son aquellos que tienen en cuenta la siguiente información para intentar predecir nuestros intereses:

- **Variable objetivo.** Las valoraciones pueden ser explícitas o implícitas, pero son siempre necesarias.
- **Características del producto (post).** Como lo visto en el filtro de contenido, son las características que definen el producto, en el caso de este TFG los Hashtags.
- **Perfil del usuario.** Información demográfica del usuario, como la edad, o de su comportamiento, como el tiempo medio que pasa. Esta información suele usarse en el método de Filtrado Colaborativo.




Figura 6.6: Preferencias similares entre Belén Esteban y María Patiño. Fuente: Elaboración propia

- **Contexto.** Información adicional de la valoración, como cuándo se hizo, dónde se hizo, etc. Se suele utilizar en recomendaciones basadas en el conocimiento.

Implementación del Algoritmo de Recomendación

En esta sección se explicará de forma detallada los pasos para implementar cada una de las técnicas de generación de recomendaciones introducidas en la sección anterior.

Filtro basado en el contenido

Para llevar a cabo este algoritmo, primero se va a seleccionar un usuario, que va a simular el primer usuario que tiene la plataforma. Una vez seleccionado un usuario, se van a crear los vectores de entrenamiento y test, como se puede observar en el Listado 6.5.

Listado 6.5: Selección de usuario y creación de vectores

```
# Selecciona un usuario
i = 7
train = dtf_train.iloc[i].to_frame(name="Interaction")
test = dtf_test.iloc[i].to_frame(name="Interaction")

# Añadir todos los productos de test pero vacíos
tmp = test.copy()
tmp["Interaction"] = np.nan
train = train.append(tmp)
train.tail()
```

El siguiente paso consiste en estimar las ponderaciones que un usuario le va a dar a cada característica. Para ello, se va a multiplicar la matriz *Posts - Categorías* con la matriz *Usuarios - Posts*. Como resultado, se obtiene la matriz *Usuarios - Características* con las ponderaciones estimadas que se le da a cada característica por cada usuario (ver Listado 6.6). Estas ponderaciones deben ser reaplicadas a la matriz *Productos - Características* para obtener las valoraciones estimadas.

Listado 6.6: Multiplicación de las matrices Post - Categorías con Usuarios - Posts

```
# Modelo
usr = train[["Interaction"]].fillna(0).values.T
pts = dtf_posts.drop(["Category"],axis=1).values
print("Users", usr.shape, " x  Posts", pts.shape)
```

Es importante a la hora de multiplicar las matrices que los tamaños sean compatibles, para evitar errores con la librería *Numpy*. Las matrices de este ejemplo tienen el tamaño declarado en el fragmento de código indicado en el Listado 6.7.

Listado 6.7: Tamaños de las matrices usadas

```
Users (1, 9999) x  Posts (9999, 49)
```

Listado 6.8: Estimación de ponderaciones

```
## usr_ft(users,features) = usr(users,posts) x prd(posts,features)
usr_ft = np.dot(usr, pts)
## normalize
weights = usr_ft / usr_ft.sum()
## predicted rating(users,posts) = weights(users,features) x prd.T(
    features,posts)
pred = np.dot(weights, pts.T)

test = test.merge(pd.DataFrame(pred[0], columns=["yhat"]), how="left",
    left_index=True, right_index=True).reset_index()
test = test[~test["Interaction"].isna()]
test
```

Tras ejecutar el código para la estimación de fragmentos, mostrado en el Listado 6.8 se obtiene la salida de que se puede observar en la Figura 6.7.

	post	Interaction	yhat
67	8066	1.0	0.308642
877	8876	1.0	0.037037
1045	9044	1.0	0.308642
1538	9537	1.0	0.037037

Figura 6.7: Tabla Predicción Interacción - Test

Para este ejemplo no se ha utilizado ninguna técnica de aprendizaje automático, solo se han llevado a cabo operaciones de matrices sencillas. Pero, como también se ha mencionado anteriormente, este proceso se puede llevar a cabo con aprendizaje automático.

Para evaluar las recomendaciones se va a utilizar la métrica [True Positive](#) [45]. También se va a tener en cuenta la [Accuracy](#) o Precisión, pero no como la métrica más importante. En el código original del artículo de referencia se utiliza el Accuracy o Precisión y el [Rango Recíproco Medio](#) (MRR) [46], los cuales son dependientes del orden en el que aparecen las recomendaciones. Mientras que, utilizando la métrica True Positive, solo se tienen en cuenta las recomendaciones, sin

importar el orden. Esto se puede observar en el fragmento de código observado en el Listado 6.9.

Es importante hacer esta aclaración, ya que el dataset que se está utilizando en este TFG está generado de forma sintética por lo que no se puede estudiar el comportamiento que hace un usuario real. Al ser sintético no se puede saber cuál es el orden de las preferencias del usuario, por lo que la Accuracy o Precisión que se suele obtener en estos ejemplos es bastante baja, en comparación con el resultado en un dataset real.

Listado 6.9: Evaluación de métricas Basado en Contenido

```
print("--- user", i, "---")

top = 5
y_test = test.sort_values("Interaction", ascending=False)["post"].values
        [:top]
print("y_test:", y_test)

predicted = test.sort_values("yhat", ascending=False)["post"].values[:top
        ]
print("predicted:", predicted)

true_positive = len(list(set(y_test) & set(predicted)))
print("true positive:", true_positive, "("+str(round(true_positive/top
        *100,1))+"%")
print("accuracy:", str(round(metrics.accuracy_score(y_test,predicted)
        *100,1))+"%")
```

Tras ejecutar el bloque de código mostrado en el Listado 6.9, lo que se obtienen son las recomendaciones que deberían aparecer para el usuario con Id 12359 (su índice es 7, por lo que $i = 7$), las recomendaciones que se predicen para dicho usuario, su True Positive y la Accuracy.

Listado 6.10: Resultados de la predicción Basado en Contenido

```
----- user 7 ---
y_test: [9506 8241 8496 8917 9124]
predicted: [8241 8917 9124 9506 8496]
```

```
true positive: 5 (100.0%)
accuracy: 0.0%
```

Se puede observar (en el Listado 6.10) como se ha conseguido predecir todos los posts que pueden gustarle al usuario, pero no ha acertado en ningún momento el orden en el que deben aparecer dichos posts.

Filtrado Colaborativo

Para llevar a cabo este método, se puede utilizar la librería *surprise* para Python para construir sistemas de recomendación a partir de valoraciones explícitas hechas por los usuarios. Además cabe destacar que este método funciona con los los métodos basados en Memoria y Modelos. En el caso de este TFG, se ha optado por utilizar la librería Tensorflow/Keras ya que permite crear modelos más sofisticados, tal y como se menciona en el artículo “*Modern Recommendation Systems with Neural Networks*” [38].

Para ello, se deben tener los datos como se puede apreciar en la Figura 6.8, a partir del código disponible en el Listado 6.11, con el que se muestra la variable interacción a predecir, y su correspondiente valor en test.

	post	Interaction	yhat
242	8241	0.75	0.259740
497	8496	0.75	0.194805
918	8917	0.75	0.259740
1125	9124	0.75	0.207792
1200	9199	0.75	0.051948
1507	9506	1.00	0.207792
1509	9508	0.50	0.051948
1692	9691	0.50	0.051948

Figura 6.8: Tabla que presenta los datos de entrenamiento para Filtrado Colaborativo

Listado 6.11: Código para preparar los datos de entrenamiento

```
train = dtf_train.stack(dropna=True).reset_index().rename(columns={0:"y"
    })
train.head()
```

El objetivo es crear la matriz de Usuarios y Posts aprovechando la Embedding Layer de una Red Neuronal. La entrada será los pares *Usuarios - Posts*, y la salida serán las valoraciones del usuario, a partir de las interacciones que ha tenido el usuario.

Para este caso, se utilizará la métrica del [Error Absoluto Medio](#), ya que este problema se está tratando como un problema de regresión. La arquitectura de la red neuronal queda como se puede ver en las Figuras 6.9 y 6.10.

Model: "CollaborativeFiltering"

Layer (type)	Output Shape	Param #	Connected to
xusers_in (InputLayer)	[(None, 1)]	0	[]
xposts_in (InputLayer)	[(None, 1)]	0	[]
xusers_emb (Embedding)	(None, 1, 50)	40000	['xusers_in[0][0]']
xposts_emb (Embedding)	(None, 1, 50)	499950	['xposts_in[0][0]']
xusers (Reshape)	(None, 50)	0	['xusers_emb[0][0]']
xposts (Reshape)	(None, 50)	0	['xposts_emb[0][0]']
xx (Dot)	(None, 1)	0	['xusers[0][0]', 'xposts[0][0]']
y_out (Dense)	(None, 1)	2	['xx[0][0]']

Figura 6.9: Arquitectura Red Neuronal - Filtrado Colaborativo en Texto

Si se entrena el modelo, con estas opciones se obtienen los resultados que se pueden observar en las Figuras 6.11 y 6.12.




Figura 6.10: Arquitectura Red Neuronal - Filtrado Colaborativo

A partir del código disponible en el Listado 6.12, se realiza el entrenamiento del modelo. Para dicho entrenamiento se ha utilizado 30 ciclos, y un tamaño de batch de 1024, evitando que la red neuronal no fuese capaz de generalizar lo suficiente debido a un elevado de número de ciclos. También se utiliza el modo verboso para poder analizar el entrenamiento por cada *epoch*.

Listado 6.12: Parámetros de entrenamiento Filtrado Colaborativo

```

# train
training = model.fit(x=[train["user"], train["post"]], y=train["y"],
epochs=30, batch_size=1024, shuffle=True, verbose=1)
model = training.model
  
```

En la Figura 6.11, se puede observar la evolución de los parámetros “pérdida” y “Porcentaje de Error Absoluto Medio”. Analizando dicha figura, se puede observar cómo estos parámetros se van reduciendo, acercándose a 0 en el caso de la pérdida y al 2% en el caso del Porcentaje de Error Absoluto Medio.




Figura 6.11: Entrenamiento - Filtrado Colaborativo

Respecto a la tabla disponible en la Figura 6.12, se puede observar en la columna *yhat* el valor de la predicción de la interacción, y en la columna *y* el valor del conjunto de test.

	user	post	y	yhat
0	0	8155	1.00	0.284512
1	0	8305	1.00	0.297998
2	0	8741	0.75	0.294089
3	0	8748	1.00	0.593709
4	0	9235	1.00	0.333105
...	...	...	...	...
9857	799	8687	0.50	0.554991
9858	799	8697	0.75	0.151637
9859	799	8947	0.75	0.424642
9860	799	9594	0.50	0.359640
9861	799	9828	0.75	0.422075

Figura 6.12: Tabla Predicción Test - Filtrado Colaborativo

Al analizar los resultados para el usuario que se ha analizado anteriormente, es decir, el usuario

con Id 12359, que corresponde al índice 7 ($i = 7$), se obtienen los valores mostrados en el Listado 6.13.

Listado 6.13: Resultados Filtrado Colaborativo

```
--- user 7 ---  
y_test: [9506 8241 8496 8917 9124]  
predicted: [9199 8496 9691 9124 9508]  
true positive: 2 (40.0%)  
accuracy: 0.0%
```

Respecto al “Método basado en contenido”, se ha reducido el True Positive, que ahora acierta 2 posts, cuando en el ejemplo anterior era capaz de predecir el 100% de los posts. Se debe tener en cuenta que esta técnica no tiene en cuenta las preferencias de los usuarios, sino cómo de parecido es un usuario respecto de otro.

Filtrado Colaborativo Neuronal

Desde 2017, se combina la Factorización de Matrices con las redes neuronales. De esta manera, se aprovecha al máximo el *Embedding space* para utilizarlo en el Filtrado Colaborativo tradicional y en una Red Neuronal de Aprendizaje Profundo Completamente Conectada (Fully Connected Deep Neural Network). La Figura 6.13 muestra la arquitectura de este tipo de método de recomendación.




Figura 6.13: Esquema de *Neural Collaborative Filtering*. Fuente: *Modern Recommendation Systems with Neural Networks* [38].

Para llevar a cabo esta red neuronal se ha utilizado la arquitectura que se puede apreciar en las Figuras 6.14 y 6.15.

Al realizar el entrenamiento de esta red neuronal con las siguientes opciones se obtienen los resultados que se pueden observar en las Figuras 6.16 y 6.17.

Model: "Neural_CollaborativeFiltering"

Layer (type)	Output Shape	Param #	Connected to
xusers_in (InputLayer)	(None, 1)	0	[]
xposts_in (InputLayer)	(None, 1)	0	[]
nn_xusers_emb (Embedding)	(None, 1, 50)	40000	['xusers_in[0][0]']
nn_xposts_emb (Embedding)	(None, 1, 50)	499950	['xposts_in[0][0]']
cf_xusers_emb (Embedding)	(None, 1, 50)	40000	['xusers_in[0][0]']
cf_xposts_emb (Embedding)	(None, 1, 50)	499950	['xposts_in[0][0]']
nn_xusers (Reshape)	(None, 50)	0	['nn_xusers_emb[0][0]']
nn_xposts (Reshape)	(None, 50)	0	['nn_xposts_emb[0][0]']
cf_xusers (Reshape)	(None, 50)	0	['cf_xusers_emb[0][0]']
cf_xposts (Reshape)	(None, 50)	0	['cf_xposts_emb[0][0]']
concatenate (Concatenate)	(None, 100)	0	['nn_xusers[0][0]', 'nn_xposts[0][0]']
cf_xx (Dot)	(None, 1)	0	['cf_xusers[0][0]', 'cf_xposts[0][0]']
nn_xx (Dense)	(None, 25)	2525	['concatenate[0][0]']
concatenate_1 (Concatenate)	(None, 26)	0	['cf_xx[0][0]', 'nn_xx[0][0]']
y_out (Dense)	(None, 1)	27	['concatenate_1[0][0]']

Figura 6.14: Arquitectura Red Neuronal Profunda - Filtrado Colaborativo en Texto

A partir del código disponible en el Listado 6.14, se realiza el entrenamiento del modelo. Para dicho entrenamiento se ha utilizado 30 ciclos, y un tamaño de batch de 512, reduciéndolo respecto el entrenamiento anterior. También utilizamos el modo verboso para poder analizar el entrenamiento por cada Epoch.




Figura 6.15: Arquitectura Red Neuronal Profunda - Filtrado Colaborativo

Listado 6.14: Parámetros de entrenamiento Filtrado Colaborativo Neuronal

```
training = model.fit(x=[train["user"], train["post"]], y=train["y"],
                    epochs=30, batch_size=512, shuffle=True, verbose=1)
```




Figura 6.16: Entrenamiento - Filtrado Colaborativo Deep Learning

	user	post	y	yhat
0	0	8155	1.00	0.778630
1	0	8305	1.00	0.733812
2	0	8741	0.75	0.797618
3	0	8748	1.00	0.815064
4	0	9235	1.00	0.773783
...	...	...	...	...
9857	799	8687	0.50	0.725232
9858	799	8697	0.75	0.722556
9859	799	8947	0.75	0.686651
9860	799	9594	0.50	0.649919
9861	799	9828	0.75	0.761815

9862 rows x 4 columns

Figura 6.17: Tabla Predicción Test - Filtrado Colaborativo Deep Learning

En la Figura 6.16, se puede observar la evolución de los parámetros “pérdida” y “Porcentaje de Error Absoluto Medio”. Analizando dicha figura, se puede observar como estos parámetros se van reduciendo, acercándose a 0 en el caso de la pérdida y también, al 0% en el caso del “Porcentaje de Error Absoluto Medio”. Respecto a la tabla disponible en la Figura 6.17, se puede observar en la

columna *yhat* el valor de la predicción de la interacción, y en la columna *y* el valor del conjunto de test.

Al analizar los resultados para el usuario que se ha analizado anteriormente, es decir, el usuario con Id 12359, que corresponde al índice 7 ($i = 7$), se obtienen los valores indicados en el Listado 6.15.

Listado 6.15: Resultados Filtrado Colaborativo Neuronal

```
--- user 7 ---
y_test: [9506 8241 8496 8917 9124]
predicted: [8917 9508 9691 8496 9124]
true positive: 3 (60.0%)
accuracy: 20.0%
```

Respecto al modelo anterior, y los resultados mostrados en el Listado 6.15 se puede observar que el True Positive aumenta en un 20% y además la Accuracy también aumenta en un 20%, ya que los posts 9124 que recomienda el sistema de recomendación coincide en las mismas posiciones que en el test.

Modelo híbrido

En la sección 6.2 se ha explicado que se tenían en cuenta las horas a las que los usuarios interactuaban con el contenido y a esa información se le ha llamado contexto.

Dicha información es la se va a añadir al conjunto de datos del entrenamiento y de test para explicar el modelo híbrido. El fragmento de código mostrado en el Listado 6.16.

Listado 6.16: Configuración Modelo Híbrido

```
# Extra data
features = dtf_posts.drop(["Category"], axis=1).columns
print(features)

context = dtf_context.drop(["user", "post"], axis=1).columns
```

```
Index(['Girl', 'Party', 'Healthy', 'Beauty', 'Ads', 'Vegan', 'Fitness',
      'Celebrities', 'Technology', 'Business', 'Cars', 'Success', '
      Aesthetic',
      'Sports', 'Style', 'Beach', 'Travel', 'Halloween', 'Selfie', 'Art
      ',
      'Design', 'Animals', 'Movies', 'Sunset', 'Marketing', 'Model',
      'Adorable', 'Yummy', 'Coffee', 'Food', 'Snow', 'Photography', '
      Winter',
      'Architecture', 'Summer', 'Makeup', 'Sky', 'Sunrise', 'Nature',
      'Friends', 'Boy', 'Cloudy', 'Music', 'Happy', 'Fashion', '
      Homeoffice',
      'Flowers', 'Christmas', 'Comedy'],
      dtype='object')
Index(['Afterwork', 'Weekend'], dtype='object')
```

```
train = dtf_train.stack(dropna=True).reset_index().rename(columns={0:"y"
    })

## add features
train = train.merge(dtf_posts[features], how="left", left_on="post",
    right_index=True)

## add context
train = train.merge(dtf_context, how="left")
```

La salida de este bloque de código se puede observar en la Figura 6.18.

	user	post	y	Girl	Party	Healthy	Beauty	Ads	Vegan	Fitness	...	Cloudy	Music	Happy	Fashion	Homeoffice	Flowers	Christmas	Comedy	Afterwork	Weekend
0	0	263	1.0	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	1	0
1	0	1185	0.5	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	1	0
2	0	1577	0.5	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	1	0
3	0	1831	1.0	0	0	0	0	1	0	0	...	0	0	0	0	0	0	0	0	0	0
4	0	1943	1.0	0	0	0	0	1	0	0	...	0	0	0	0	0	0	0	0	0	0

5 rows x 54 columns

Figura 6.18: Nuevos datos de entrenamiento

Listado 6.17: Prueba del modelo

```
test = dtf_test.stack(dropna=True).reset_index().rename(columns={0:"y"})

## add features
test = test.merge(dtf_posts.drop(["Category"], axis=1), how="left",
                  left_on="post", right_index=True)

## add context
test[context] = 0 #--> simulate production for a weekday night
#test = test.merge(dtf_context, how="left") #--> use test set
```

La salida del bloque de código del Listado 6.17 se puede observar en la Figura 6.19.

	user	post	y	Girl	Party	Healthy	Beauty	Ads	Vegan	Fitness	...	Cloudy	Music	Happy	Fashion	Homeoffice	Flowers	Christmas	Comedy	Afterwork	Weekend
0	0	8155	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
1	0	8305	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
2	0	8741	0.75	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
3	0	8748	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0
4	0	9235	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0

5 rows x 54 columns

Figura 6.19: Nuevos datos de test

Las redes neuronales tienen una gran flexibilidad, por lo que se les puede añadir todos los módulos que sean necesarios. En el artículo *Modern Recommendation Systems with Neural Networks* [38] se presenta la siguiente arquitectura simplificada que se puede ver en la Figura 6.20.

La arquitectura de la red neuronal que se ha elaborado se puede observar en las Figuras 6.21 y 6.22.




Figura 6.20: Arquitectura Simplificada Modelo Híbrido. Fuente: *Modern Recommendation Systems with Neural Networks* [38].

Model: "Hybrid_Model"

Layer (type)	Output Shape	Param #	Connected to
xusers_in (InputLayer)	[(None, 1)]	0	[]
xposts_in (InputLayer)	[(None, 1)]	0	[]
nn_xusers_emb (Embedding)	(None, 1, 50)	40000	['xusers_in[0][0]']
nn_xposts_emb (Embedding)	(None, 1, 50)	499950	['xposts_in[0][0]']
cf_xusers_emb (Embedding)	(None, 1, 50)	40000	['xusers_in[0][0]']
cf_xposts_emb (Embedding)	(None, 1, 50)	499950	['xposts_in[0][0]']
nn_xusers (Reshape)	(None, 50)	0	['nn_xusers_emb[0][0]']
nn_xposts (Reshape)	(None, 50)	0	['nn_xposts_emb[0][0]']
cf_xusers (Reshape)	(None, 50)	0	['cf_xusers_emb[0][0]']
cf_xposts (Reshape)	(None, 50)	0	['cf_xposts_emb[0][0]']
concatenate_2 (Concatenate)	(None, 100)	0	['nn_xusers[0][0]', 'nn_xposts[0][0]']
features_in (InputLayer)	[(None, 49)]	0	[]
contexts_in (InputLayer)	[(None, 2)]	0	[]
cf_xx (Dot)	(None, 1)	0	['cf_xusers[0][0]', 'cf_xposts[0][0]']
nn_xx (Dense)	(None, 25)	2525	['concatenate_2[0][0]']
features_x (Dense)	(None, 49)	2450	['features_in[0][0]']
context_x (Dense)	(None, 2)	6	['contexts_in[0][0]']
concatenate_3 (Concatenate)	(None, 77)	0	['cf_xx[0][0]', 'nn_xx[0][0]', 'features_x[0][0]', 'context_x[0][0]']
y_out (Dense)	(None, 1)	78	['concatenate_3[0][0]']

Figura 6.21: Arquitectura Red Neuronal Modelo Híbrido en Texto




Figura 6.22: Arquitectura Red Neuronal Modelo Híbrido

Se ha realizado el entrenamiento de esta red neuronal con las opciones que se indican en el fragmento de código mostrado en el Listado 6.18. Utilizando un tamaño de Batch de 512 y un número de ciclos de 30, a parte de utilizar de nuevo el modo verboso.

Listado 6.18: Parámetros de configuración del modelo híbrido

```
training = model.fit(x=[train["user"], train["post"], train[features],
                        train[context]], y=train["y"],
                    epochs=30, batch_size=512, shuffle=True, verbose=1)
model = training.model
```

Los resultados de este entrenamiento se pueden observar en las Figuras 6.23 y 6.24.




Figura 6.23: Entrenamiento - Modelo Híbrido

	user	post	y	Girl	Party	Healthy	Beauty	Ads	Vegan	Fitness	...	Music	Happy	Fashion	Homeoffice	Flowers	Christmas	Comedy	Afterwork	Weekend	yhat
0	0	8155	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.685313
1	0	8305	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.902695
2	0	8741	0.75	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.820309
3	0	8748	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.772805
4	0	9235	1.00	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.896417
...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...	...
9857	799	8687	0.50	0	1	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.704701
9858	799	8697	0.75	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.704080
9859	799	8947	0.75	0	0	0	0	0	0	0	...	0	0	1	0	0	0	0	0	0	0.753199
9860	799	9594	0.50	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.655335
9861	799	9828	0.75	0	0	0	0	0	0	0	...	0	0	0	0	0	0	0	0	0	0.600515

9862 rows x 55 columns

Figura 6.24: Tabla Predicción Test - Modelo Híbrido

En la Figura 6.23 se puede observar la evolución de los parámetros “Pérdida” y “Porcentaje de Error Absoluto Medio”. Analizando dicha figura, se puede observar como estos parámetros se van reduciendo, acercándose a 0 en el caso de la pérdida y también al 0% en el caso del Porcentaje de Error Absoluto Medio. Respecto a la tabla disponible en la Figura 6.24, se puede observar en la columna *yhat* el valor de la predicción de la interacción, y en la columna *y* el valor del conjunto de test.

Al analizar los resultados para el usuario que se ha analizado anteriormente, es decir, el usuario con Id 12359, que corresponde al índice 7 ($i = 7$), se obtienen los siguientes valores, mostrados en el Listado 6.19.

Listado 6.19: Resultados del modelo híbrido

```
--- user 7 ---  
y_test: [9506 8241 8496 8917 9124]  
predicted: [9506 9199 8241 8917 9124]  
true positive: 4 (80.0%)  
accuracy: 60.0%
```

Como se puede observar en el Listado 6.19, se ha conseguido un True Positive bastante alto, del 80%, que aunque no es como en el del primer caso, teniendo en cuenta la Accuracy, se obtiene que esto significa que se tienen buenas recomendaciones para este usuario. Eso es debido a que existe una gran probabilidad de que al usuario con Id 12359 le gusten la mayoría de los posts que se le presentan, además en el orden adecuado para dicho usuario.

Se debe recordar que en el modelo híbrido, la red neuronal tiene en cuenta el contexto del usuario, es decir, a qué hora está visualizando contenido y si es en fin de semana o no, es decir, en su tiempo libre, como se ha explicado anteriormente. En el caso de este ejemplo, se puede comprobar observando en la Figura 6.18 dos nuevas columnas en la tabla, las cuales son *Afterwork* y *Weekend*.

7. Objetividad de los Algoritmos de Recomendación

En el capítulo anterior, se ha visto cómo funcionan a un nivel más técnico los algoritmos de recomendación que pueden utilizar las redes sociales o incluso otro tipo de servicios como Netflix o Amazon. Estos sistemas siempre intentan ofrecer el contenido, o productos en el caso de Amazon, más adecuados a las preferencias de sus usuarios, y todo ello lo hacen a partir de las interacciones que hacen los usuarios en la plataforma o bien que un usuario ha indicado explícitamente.

Ahora bien, en la sociedad actual mucha gente duda de si se intenta manipular a los ciudadanos para que unos pocos decidan todo lo que hace la población. Existe la creencia en una parte de la sociedad de que las redes sociales y las TIC intentan “alienar” a la población [47], o generar necesidades que las personas no tenían al principio y ahora es indispensable para la vida. La pregunta que se debe realizar es ¿es eso posible actualmente?.

En este capítulo se va a analizar la posibilidad de hacer esto mediante los sistemas de recomendación, utilizando las redes neuronales que se han diseñado para el capítulo anterior. Para ello se va a plantear la hipótesis H_1 , tal y como se presenta a continuación.

H1: Es posible fomentar la recomendación de una mayor cantidad de posts de la categoría “Vegan” de manera sintética.

7.1 Conjunto de datos

Se va a utilizar el mismo dataset que se ha utilizado en el Capítulo 6. La diferencia principal en este caso, es que se va cambiar el peso que se le asigna a las interacciones que tenga un post relacionado

con el Veganismo.

El procedimiento a la hora de importar los datos sobre los posts es el mismo que para las otras redes neuronales del capítulo anterior. Lo que difiere es el tratamiento de los datos de las interacciones de los usuarios.

La diferencia respecto al capítulo anterior reside en que el peso de la interacción que ha tenido un usuario con un post de la categoría *Vegan* va a ser 1000 en todos los casos, aunque la interacción haya sido negativa. Lo que lo puntúa 2 puntos por encima de la interacción más alta que era el comentario. Para ello, se va a tener que añadir el número de post y la categoría a la que pertenece el post. Posteriormente, se cambiará el valor de la interacción donde sea necesario. Esto se puede observar en el Listado 7.1.

Listado 7.1: Cambio en la interacción para la hipótesis H1

```
dtf_users = dtf_users.merge(dtf_posts[["PostId", "post", "Category"]],
                             how="left")

def change_Interaction(Category, Interaction):
    if Category == 'Vegan' :
        return 1000
    else:
        return Interaction

dtf_users["Interaction"] = dtf_users.apply(lambda x : change_Interaction(
    x["Category"], x["Interaction"]), axis=1)
```

En la Figura 7.1 aparecen señaladas las nuevas columnas.

También se deja de aplicar la técnica de Escalado de Datos, por lo que se eliminará el bloque de código que se muestra en el Listado 7.2

Listado 7.2: Escalado de datos

```
dtf_users = pd.DataFrame(preprocessing.MinMaxScaler(feature_range=(0.5,1)
    ).fit_transform(dtf_users.values), columns=dtf_users.columns, index=
```

	UserId	PostId	Interaction	Timestamp	user	Afterwork	Weekend	post	Category
0	13252	2203	3	2023-01-01 07:16:41	0	0	1	2202	Adorable
1	13252	6421	3	2023-05-28 01:47:40	0	1	1	6420	Adorable
2	13252	8749	3	2022-11-28 08:17:45	0	0	0	8748	Adorable
3	13252	2634	3	2022-10-09 03:12:55	0	1	1	2633	Adorable
4	13252	1944	3	2022-11-14 19:12:18	0	0	0	1943	Ads
...	...	...	...	...	...	...	...	...	...
49994	14051	7040	-1	2023-02-27 20:39:47	799	1	0	7039	Design
49995	14051	7603	-1	2023-04-08 03:29:50	799	1	1	7602	Party
49996	14051	7771	-1	2022-11-06 06:16:16	799	1	1	7770	Photography
49997	14051	8688	-1	2023-05-28 10:19:55	799	0	1	8687	Party
49998	14051	9595	-1	2022-08-12 01:20:46	799	1	0	9594	Nature

Figura 7.1: Tabla de datos de entrenamiento modificada.

```
dtf_users.index)
```

Debido a esto también se aplican cambios a los entrenamientos de las redes neuronales, que se irán analizando individualmente. Para el análisis vamos a utilizar al usuario con Id 13568, con índice 316 en el código ($i = 316$).

7.2 Método Basado en Contenido

Si se observan los resultados obtenidos para el Usuario 13568 mostrados en la sección anterior, se puede obtener un 80% del True Positive, es decir, 8 de 10 posts recomendados coinciden con los valores de test. Además, los posts 9972, 8634 y 8632 son posts de la categoría Vegan, por lo que se ha conseguido posicionar que nada más entrar al servicio, aparezcan posts de dicha categoría, tal y como se muestra en el Listado 7.3.

Listado 7.3: Resultados de test para la hipótesis 1

```
--- user 316 ---
y_test: [9971 8633 8631 8196 8204 8122 8970 9916 9553 9243]
predicted: [9971 8633 8196 8204 8122 8631 9243 8970 8715 8924]
true positive: 8 (80.0%)
```

accuracy: 20.0%

Nota: Los posts que aparecen en los resultados siempre aparecen con una diferencia de 1 unidad en el Id, es decir, cuando en la salida aparece el post con 9971, se refiere al Post con Id 9972.

7.3 Filtrado Colaborativo

Esta técnica es la primera en la que aparece una red neuronal. Para entrenar dicha red neuronal, cuya arquitectura está disponible en el Capítulo 6 se han utilizado los siguientes parámetros mostrados en el Listado 7.4.

Listado 7.4: Filtrado colaborativo: parámetros configuración hipótesis 1

```
training = model.fit(x=[train["user"], train["post"]], y=train["y"],
                    epochs=50, batch_size=512, shuffle=True, verbose=1)
```

Se ha incrementado el número de Epochs, debido a que al quitar el escalado de datos la pérdida y el porcentaje de error absoluto se reducirían de una manera más lenta a la del modelo original. Con dichos datos de entrenamiento, para el usuario que se está estudiando ($Id = 13568$) se obtienen resultados mostrados en el Listado 7.5.

Listado 7.5: Resultados Filtrado Colaborativo H1

```
--- user 356 ---
y_test: [8251 8869 8003 8294 9434]
predicted: [9434 8251 9601 8003 8869]
true positive: 4 (80.0%)
accuracy: 0.0%
```

Respecto al Método Basado en el Contenido se obtiene un True Positive parecido, pero la Accuracy en cambio baja al 0%. Aunque se recuerda lo que se ha mencionado en el Capítulo 6, debido a la naturaleza del dataset, no se tendrá demasiado en cuenta a la Accuracy.

Ahora bien, respecto a la intención de que aparezcan posts de la categoría *Vegan* al usuario, se obtiene que se recomiendan los posts con Id 8252 y 8870, que ambos pertenecen a la categoría *Vegan*.

7.4 Filtrado Colaborativo con Deep Learning

La arquitectura está disponible en el Capítulo 6. Al igual que para el método anterior, se ha incrementado el número de Epochs. Los parámetros de entrenamiento quedan de la siguiente forma (ver Listado 7.6).

Listado 7.6: Configuración Filtrado Colaborativo con DL para H1

```
# train
training = model.fit(x=[train["user"], train["post"]], y=train["y"],
                    epochs=50, batch_size=256, shuffle=True, verbose=1)
```

Con dichos datos de entrenamiento, para el usuario que se está estudiando ($Id = 13568$) se obtienen los siguientes resultados (ver Listado 7.7).

Listado 7.7: Resultados Filtrado Colaborativo con DL para H1

```
--- user 356 ---
y_test: [8251 8869 8003 8294 9434]
predicted: [9434 8869 8900 8003 9742]
true positive: 3 (60.0%)
accuracy: 20.0%
```

Analizando los resultados, se obtiene un menor True Positive que en el modelo anterior, ya que la red neuronal predice correctamente un post menos que en el modelo anterior, aunque se consigue que se aumente la Accuracy acertando el orden del segundo post que recomienda el algoritmo.

Respecto a la intención de mostrar posts de la categoría *Vegan*, se obtiene el Post 8870 que pertenece a la categoría *Vegan*, por lo que al menos somos capaces de que un post de esta categoría aparezca en las primeras posiciones.

7.5 Modelo Híbrido

La arquitectura está disponible en el Capítulo 6. Al igual que para el método anterior, se ha incrementado el número de Epochs. Los parámetros de entrenamiento quedan de la forma que muestra el Listado 7.8.

Listado 7.8: Configuración modelo híbrido H1

```
# train
training = model.fit(x=[train["user"], train["post"], train[features],
                        train[context]], y=train["y"], epochs=50, batch_size=256, shuffle=
                        True, verbose=1)
```

Con dichos datos de entrenamiento, para el usuario que se está estudiando ($Id = 13568$) se obtienen los siguientes resultados mostrados en el Listado 7.9.

Listado 7.9: Resultados del modelo híbrido H1

```
--- user 356 ---
y_test: [8251 8869 8003 8294 9434]
predicted: [8251 8869 8900 9434 8294]
true positive: 4 (80.0%)
accuracy: 40.0%
```

Analizando los resultados, se puede observar que el True Positive mejora, respecto al modelo de Deep Learning que se ha visto en la sección anterior, volviendo a los valores originales. Además, la Accuracy también mejora, consiguiendo que los dos primeros posts coincidan con los valores de test.

Respecto a los posts con categoría *Vegan*, se ha conseguido que sean los dos primeros posts en aparecer cuando el usuario arranca el servicio. Dichos posts son aquellos con Id 8252 y 8870.

7.6 Análisis de los resultados

A partir de los resultados obtenidos en las secciones 7.2, 7.3, 7.4 y 7.5 se puede ver cómo es de factible poder modificar un algoritmo de recomendación para que aparezcan contenidos, que con los que haya interactuado alguna vez el usuario, en posiciones más favorables que la de otros posts. Esto confirma la hipótesis H_1 planteada al comienzo de este capítulo.

Confirmar esta hipótesis abre la puerta a la confirmación del hecho de que los usuarios de las redes sociales no saben realmente que les está recomendando la red social. A pesar de que se recojan datos sobre los usuarios para saber cuáles son sus preferencias, puede que se les muestre contenido que realmente no les interesa, pero que por fines económicos o de otras índoles se les presente.

Esto se puede llevar a un más lejos cuando las redes sociales son capaces de identificar de qué tipo es el contenido que se ha subido, por lo que incluso se pueden llegar a hacer “recomendaciones” de contenidos políticos con algún discurso que pueda contener mentiras. Dicho contenido al usuario no le interesa, pero aunque no le guste, puede que vea el contenido, lo que conlleva que dicho usuario pueda creerse la mentira que se dice en dicho post, lo cual puede llevar al usuario a cambiar su opinión sobre ciertos temas.

Al final las redes sociales tienen detrás empresas que buscan obtener un beneficio a partir de la publicidad que les muestra al usuario, y eso implica que, para un mayor beneficio económico, el usuario debe pasar más tiempo en la red social. Si un post se convierte en viral, aunque sea una mentira, es lo que coloquialmente se conoce como “una máquina de hacer dinero”, por lo que sin tener en cuenta la ética ni otros factores que no sean el económico, van a seguir potenciando ese post para obtener la mayor cantidad de dinero posible.

8. Análisis de la situación actual

En 2020, Netflix publicó el documental *The Social Dilemma* [48], en el que algunos ex-empleados de las empresas de redes sociales más grandes de Silicon Valley y psicólogos comentan algunos aspectos negativos sobre las redes sociales y sobre los problemas que han creado en la población y en sus usuarios, así como algunos escándalos que han aparecido en los últimos años.

Uno de los principales problemas que se presenta es la adicción que generan las redes sociales, y una gran parte denuncian que este hecho es debido a los algoritmos de recomendación, tal y como se analizaba en el Capítulo 4. Otro de los grandes problemas que están generando las redes sociales, y se presenta en el documental, son los problemas de salud mental que pueden causar en los usuarios debido a las comparaciones que se hacen continuamente en las redes sociales, o como las consecuencias que se han visto en el Capítulo 5.

En este mismo documental se menciona que los adolescentes que padecen depresión y/o ansiedad han crecido de una manera considerable. Por ejemplo, desde 2010, que fue cuando comenzó el auge de las redes sociales, el ingreso hospitalario en **mujeres adolescentes** ha aumentado un 62% y un 189% en mujeres Pre-adolescentes, tal y como se puede observar en las Figuras 8.1 y 8.2.

Respecto a la tasa de suicidio, que se puede observar en las Figuras 8.3 y 8.4, esta ha aumentado un 70% en adolescentes y un 151% en Pre-adolescentes.

Algunos expertos en el documental comentaban que este incremento de suicidios se debe a que la Generación Z es la primera generación en acceder a las redes sociales desde la pre-adolescencia, lo que ha llevado a que dicha generación a ser más ansiosa, frágil y en general más deprimida, siendo las redes sociales un “chupete” al que pueden acceder con extremada facilidad. Respecto a la salud mental, también hay que considerar los problemas de dismorfia corporal que generan estas redes sociales [50], debido a las comparaciones que se hacen continuamente entre los físicos de los usuarios. También los usuarios pueden llegar a comparar su estilo de vida con el de otras personas, pensando que su vida es inferior a la de estos otros. Estas situaciones se relacionan directamente




Figura 8.1: Tasa de Ingresos Hospitalarios de Mujeres Adolescentes entre los años 2001 y 2015 por cada 100,000 mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]




Figura 8.2: Tasa de Ingresos Hospitalarios de Mujeres Pre-adolescentes entre los años 2001 y 2015 por cada 100,000 mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]

con las tasas de suicidio y la probabilidad de padecer problemas de salud mental. A ello se le suma que en estas redes sociales pueden aparecer contenidos como las dietas milagro o aspectos nocivos para la salud para conseguir un cuerpo que se ajuste a los estándares de belleza actuales, y a pesar de que estas “técnicas mágicas” son peligrosas, le siguen apareciendo a los usuarios de las redes sociales debido a sus algoritmos de recomendación.




Figura 8.3: Tasa de Suicidio en Mujeres Adolescentes entre los años 2000 y 2018 por cada millón de mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]




Figura 8.4: Tasa de Suicidio en Mujeres Pre-adolescentes entre los años 2000 y 2018 por cada millón de mujeres en Estados Unidos. Fuente: Centers for Disease Control and Prevention [49]

Es cierto que estos hábitos insalubres existen desde hace mucho tiempo, pero el problema radica en la facilidad con la que llegan a los usuarios por los sistemas de recomendación.

Las redes sociales pueden utilizarlas cualquier persona de manera gratuita, por lo que se puede plantear la pregunta: *¿De dónde obtienen los ingresos las empresas dueñas de estas aplicaciones?*. Las redes sociales obtienen la mayoría de sus ingresos a través de los anunciantes de su plataforma o de los datos que recogen sobre sus usuarios. Por lo que, *¿Quiénes son los verdaderos clientes de las redes sociales?*.

Cuando se habla de un usuario que utiliza Netflix o Amazon se habla de clientes, pero cuando se habla de los usuarios que utilizan las redes sociales es extraño llamarlo *cliente*, sobretodo porque no hacen ninguna transacción. Por este motivo, los verdaderos clientes de las redes sociales son los *anunciantes*, lo que convierte a los usuarios en los productos que venden a los anunciantes, en concreto la atención de los usuarios. Al ser la atención de los usuarios el producto con el que se consigue el beneficio, es importante mantener a los usuarios el mayor tiempo posible en la aplicación, utilizando para ello los algoritmos de recomendación y las constantes notificaciones para llamar la atención del usuario, causando la adicción a las redes sociales.

Además, en el Capítulo anterior (Capítulo 7) se ha visto que la objetividad de los algoritmos reside en sus creadores, ya que éstos pueden modificarlos según sus objetivos y necesidades. Cada usuario en las redes sociales tiene un *feed* personalizado (o tablero personalizado), con sus intereses, cuentas que sigue, contenido de gente que no sigue pero que puede interesarle a ese usuario, etc. Todo esto aparece en un orden específico a partir de los datos que recogen sobre sus usuarios.

Al final, cada usuario ve lo que “quiere” ver, según lo ha definido la red social, por lo que todo el contenido que le aparece al usuario va a ser afín a él. Esto quiere decir que si aparecen noticias en el *feed*, dichas noticias van a aparecer de tal manera que al usuario que le han aparecido le gusten, lo que hace que solo vea parte de la realidad, provocando que el usuario no tenga una visión completa sobre ciertos acontecimientos.

Esto también está provocando, en cierta medida, la polarización de la sociedad, ya que al solo ver una parte de la realidad, está se va radicalizando más, según comentan en el documental. Además, dicha radicalización provoca un mayor nivel de ingresos a las redes sociales por la viralización, ya que es mucho más fácil vender un artículo con un título “jugoso”, a un artículo que pueda pasar desapercibido.

En la Figura 8.5 se puede observar un titular bastante “jugoso” sobre la Ministra de Igualdad del Gobierno de España, Irene Montero. Aunque lo que menciona el tweet sea una opinión personal, los autores de dicho tweet saben, por cómo son las redes sociales, que ese tweet iba a alcanzar muchas visitas, en el caso de dicho tweet un millón. A esto hay que añadir que dicha opinión atenta sobre una política, en una campaña de desprestigio y no sobre su trabajo, sino por ser la “mujer de...”.



Figura 8.5: Captura de pantalla de un Tweet de una opinión sobre Irene Montero

Otro ejemplo, según La Marea [51], en julio de 2023 fue asesinada una comerciante en Tirso de Molina en Madrid. El problema ocurre cuando un periódico afirma que los asesinos de dicha mujer eran de origen magrebí. Sin consultar si esa información era veraz, el líder del partido político VOX compartía dicha noticia, como se puede ver en la Figura 8.6. Dicho tweet alcanzó más de 5 millones de visualizaciones. El País [52] sería el encargado de desmentir dicha información, pero esta solo estaría disponible en su artículo, y no en el tweet que publicaron al respecto, como se puede ver en la Figura 8.7. Además dicho tweet solo tuvo 200 mil visitas.



Figura 8.6: Captura de pantalla de un Tweet del líder del partido político VOX.



Figura 8.7: Captura de pantalla del Tweet del periódico El País.

Esto no solo es solo un caso aislado en artículos periodísticos, la desinformación y cómo se propaga puede ocurrir con diversos temas. Por ejemplo, un caso que se viralizó bastante es el caso del Pizzagate [53]. Este caso fue una teoría de la conspiración, que resultó en un bulo, respecto al tráfico de personas y pedofilia que se extendió con gran rapidez durante las elecciones presidenciales de los Estados Unidos. En el documental también se comenta que a las personas que consumían contenido sobre el Pizzagate, el sistema de recomendación le mostraba posts sobre antivacunas, fomentando más bulos. A pesar de que el Pizzagate era un bulo, en las redes sociales corría como polvora, por el dinero que estaba generando para las empresas.

Por otro lado, en El Periódico [54] se publicó que ex-miembros de Facebook, , actualmente Meta, denunciaron públicamente la inacción que la empresa hacía respecto a los perfiles falsos para fomentar la desinformación política, y cómo lo que puntúa sus algoritmos es la viralización y no la veracidad. Esto deja una situación en la que las redes sociales pueden manipular la opinión pública solo por intereses económicos para una gran empresa o partidos políticos.

Según El País [55], los escándalos no terminan aquí. Retomando el tema de la salud mental, Facebook, publicó en documentos internos de la compañía estudios en los que observaban la toxicidad de Instagram hacia las adolescentes, obteniendo que al menos un 32% de las adolescentes se sentían mal por su cuerpo por culpa de Instagram. La situación se hace más grave cuando el líder de Facebook intentó desmentir esta información y ocultarla indicando que *“La investigación que hemos visto es que usar aplicaciones sociales que te conectan con otra gente puede tener beneficios mentales positivos”*.

A esto se le suma otros casos de Facebook en los que, a pesar de ir en contra de sus políticas o de legislación internacional, había contenido sobre tráfico de personas o incluso imágenes violentas que Facebook era consciente de que existían, y en cambio la red social no hacía lo suficiente. Adicionalmente, esta empresa tiene dificultades para que se apliquen sus políticas respecto a estos contenidos, según la investigación de *“The Wall Street Journal”* que comenta el País [55].

Esto deja a las redes sociales en una situación en la que, con sus algoritmos de recomendación, fomentan que los usuarios pasen más tiempo en su red social, creando adicciones. Con los posts que van recomendando también crean problemas de salud mental a los adolescentes. A parte, esos algoritmos fomentan la polarización y que los usuarios no vean la realidad, y hacen que solo vean la parte que a ellos les interesa. Como consecuencia de esto, las redes sociales modelan al antojo de un algoritmo la realidad de los jóvenes y adolescentes, que todavía no disponen de las herramientas y la experiencia necesaria para ser capaces de distinguir qué elementos viralizados son reales, o simplemente son un bulo que interesa viralizar. Situación de la que las empresas son conscientes, pero prefieren seguir ganando dinero de esta manera tan sencilla pero en algunos casos poco ética.

9. Aspectos legales, éticos y sociales e impacto

Las redes sociales son utilizadas por millones de usuarios en el día a día, por lo que es importante que lo que está en manos de un par de grandes empresas, que tienen sus propios objetivos, sigan ciertas normas tanto a nivel legislativo como a nivel ético. A parte de que estas tienen un gran componente social, y económico en lo que respecta a los anunciantes.

9.1 Aspectos legales, éticos y profesionales

En este TFG se intenta dar una visión sobre la ética que tienen las redes sociales y sus algoritmos respecto a los objetivos que intentan perseguir las empresas dueñas de estas. En el Capítulo 8 se puede relacionar fácilmente la falta de ética que tienen estas empresas cuando, prefieren dar versiones modificadas de la realidad en pro de obtener, las empresas, un beneficio económico con la viralización de bulos, teorías de la conspiración y contenido que de visitas en general. Además, demostrar todavía más falta de ética cuando se demuestra que tu red social está dañando la salud mental de los jóvenes, intentando esconderlo únicamente con las ventajas que tus redes sociales ofrecen. También se puede observar cómo hay personas que conocen cómo funcionan estas redes sociales, como se ha visto en el Capítulo 8. Esto se ha producido aprovechando cómo se viralizan los tweets para distribuir mentiras en la red o incluso atacar a otras personas, fomentando el odio hacia estas.

El problema reside en qué es muy difícil que una vez se ha difundido un bulo, la realidad se difunda tan rápido como lo ha hecho el bulo, lo que provoca que mucha gente resida en una realidad que no existe. Es cierto que algunas redes sociales, como Twitter, ha incluido la funcionalidad de añadir contexto a los enlaces de noticias, pero sigue siendo una función insuficiente, ya que no todo el

mundo llega a leer el contexto de dicha noticia.

Por otro lado, también se ha tenido en cuenta la relación con los aspectos legales con las restricciones que se han tenido para poder obtener datos reales de interacciones en redes sociales, tal y como se menciona en el Capítulo 6 debido a la legislación Europea de protección de datos. Pero, hay que hacer mención especial a la pasividad que tienen las empresas respecto a la privacidad de datos [42], saltándose dicha normativa. Por ejemplo, Facebook se ha saltado dicha normativa reiteradas veces, para obtener beneficio económico sobre los datos de los usuarios de sus redes sociales, así como demuestran en el artículo *“Multa histórica de 1.200 millones a Facebook por violar la política de protección de datos de la UE”* de elEconomista [56].

Esto deja a las empresas propietarias de las redes sociales ante una posición en la que su ética es bastante dudosa y por cómo la, salud mental de sus usuarios o las consecuencias que tienen en la sociedad la viralidad, pasa a ser un aspecto secundario solo por obtener un beneficio económico.

9.2 Impacto social, económico y medioambiental

Las redes sociales, al comunicar personas, tienen un gran impacto en el ámbito social. Ya no solo porque comunican personas, sino porque actualmente, al mostrar contenido diferente a todos los usuarios (como se ha visto en capítulos anteriores), pueden moldear la realidad a los objetivos de la empresa propietaria.

Además, en este TFG se ha estudiado el impacto que tienen estos servicios en los jóvenes y adolescentes, observando la adicción que generan y los problemas que están causando en los jóvenes, provocando incluso la muerte, tasas que por desgracia no dejan de aumentar con el paso de los años.

Respecto al ámbito económico, las redes sociales mueven grandes cantidades de dinero, debido al gran volumen de usuario que tienen. El problema reside en que la manera de la que están haciendo dichas cantidades, puede que no sea la forma más ética posible, ya que están mintiendo en cierta medida a sus usuarios.

Los ingresos que perciben, como se ha mencionado anteriormente en el Capítulo 8, vienen de los anunciantes, es decir, de cuánta atención se le puede robar al usuario para que visualice el mayor número de anuncios posible. Esto provoca el enriquecimiento de las redes sociales a costa de,

como se ha comprobado, la propia salud de las personas y de los jóvenes. Pero no es únicamente un problema de las empresas que poseen las redes sociales, los anunciantes también aprovechan esa adicción para intentar vender la mayor cantidad de productos posibles. A esto se le suma que hay empresas anunciantes de ciertos productos de dudosa calidad para la salud de los usuarios.

Esto desemboca en grandes corporaciones obteniendo grandes beneficios, a costa de los usuarios y de una población vulnerable, como pueden ser los jóvenes, que ponen en juego su salud, sus opiniones e incluso parte de su realidad, porque todavía no han desarrollado las suficientes herramientas para diferenciar que aspectos son reales y qué no de todo lo que consumen en Internet.

Por ese motivo, este TFG tendría un impacto económico negativo, al menos para dichas empresas, ya que publicar que una empresa miente a sus usuarios y que los utiliza para ganar dinero mediante, hablando en palabras mayores, la manipulación, puede provocar que muchos usuarios decidan abandonar sus servicios.

10. Conclusiones y trabajo futuro

Las redes sociales y sus algoritmos han provocado grandes problemas a nivel social o incluso de salud, ocasionando incluso la muerte de jóvenes y adolescentes. También, han ignorado estos problemas a costa de la viralidad que dan, y del beneficio que esta produce. Todo esto, a costa de sus usuarios prácticamente con impunidad.

10.1 Conclusiones

Las redes sociales, a pesar de ser una forma en la que las personas pueden comunicarse de manera sencilla y consumir entretenimiento de una manera más cómoda, estas tienen bastantes puntos negativos en lo que respecta, sobretodo, hacia los jóvenes y adolescentes. El uso de los algoritmos de recomendación para fines poco éticos algunos de los cuales son utilizados en estas redes sociales provocan la adicción de aproximadamente 1 de cada 3 jóvenes, provocando problemas de salud mental como depresión o ansiedad, lo que aumenta el riesgo de suicidio de los jóvenes. Este TFG ha demostrado la facilidad con la que se pueden trucar o modificar los algoritmos de recomendación para manipular los contenidos que le pueden aparecer a usuarios vulnerables que pueden ser blancos fáciles de fines oscuros, perversos o simplemente usuarios manipulables para que se muestre el contenido que su creador quiera.

Además, se ha podido concluir, que las empresas propietarias de las redes sociales, fomentan la viralización de contenidos con sus algoritmos que no son siempre reales, pero que por la polémica que generan, permiten que esos posts se sigan compartiendo. De esta manera, los propietarios de estos servicios obtienen grandes beneficios, a pesar de la ausencia de realidad hacia sus usuarios, porque para las redes sociales, la atención de sus usuarios es meramente un producto que vender a sus verdaderos clientes, los anunciantes.

El principal problema reside en la dificultad de los usuarios para detectar esta situación. Las re-

des sociales son tan amigables que nublan la atención, sobretodo, de los jóvenes, con contenido que parece banal o no lo suficientemente importante, pero que detrás se esconden grandes corporaciones intentando obtener siempre el mayor beneficio. Desde las instituciones debe tratarse la adicción a las redes sociales y las consecuencias que traen los algoritmos de recomendación, intentando concienciar a los usuarios en un primer paso, y/o blindando de manera jurídica aspectos dirigidos sobretodo a la salud de los usuarios de las redes, o la información que se distribuye a través de estas. Sin las instituciones, la sociedad no va a ser consciente de los problemas que traen dichos algoritmos, y que a pesar de que sean buenas herramientas, actualmente están diseñadas de una manera “hostil”.

También hay que recalcar que las “IAs”, o como comúnmente se les llama a los algoritmos inteligentes, que utilizan en las redes sociales, a pesar de que al principio no se puede saber cuáles van a ser sus resultados, están entrenadas de tal manera que no tienen en cuenta los problemas que pueden ocasionar. Esto obliga a que los algoritmos que se utilicen en aspectos sociales, deben estar entrenadas con ciertos límites éticos, y respetando los derechos humanos, aspecto que por ejemplo en el Capítulo 8 con el caso de Facebook no cumplen, porque las “IAs” no son capaces de detectar que se saltan las propias condiciones que impone Facebook.

Esta característica es lo que hace definir a algunos algoritmos inteligentes, sobre todo aquellos que aplican técnicas de aprendizaje automático profundo, a ser descritos como modelos de “caja negra”. Esto es debido a que es difícil interpretar la razón que subyace a los resultados ofrecidos por estos modelos o algoritmos. Debido a estas razones, existe una brecha entre la aplicación real en contextos industriales y sociales y estos modelos. En diversos campos de aplicación donde es importante conocer la naturaleza de las decisiones tomadas por estos algoritmos y donde cada resultado debe estar respaldado por un conjunto de pasos bien definidos se requiere una IA explicable (XAI). Este término se refiere al conjunto de procesos y métodos que permiten a los usuarios humanos comprender y confiar en los resultados creados por algoritmos de aprendizaje automático [57]. La explicabilidad o a menos la transparencia de la información a los usuarios de la forma cómo los algoritmos usan sus datos debería ser algo mandatorio en el uso de las IAs y más aún en aquellas que trabajan sobre redes sociales.

En este sentido, cualquier conjunto de acciones que permitan aportar pedagogía a la sociedad sobre estas actuaciones podría aportar conciencia sobre el nivel de responsabilidad de cada usuario en el uso de las redes sociales.

También es importante una mejora en el apartado jurídico, para proteger a los jóvenes ante la viralización de los bulos y proteger su salud mental. Además, desde las instituciones fomentar la concienciación sobre las consecuencias de las redes sociales, demostrando qué efectos sobre la

salud de los jóvenes tiene. Es importante que esta concienciación no se haga únicamente a los propios jóvenes, sino a todos los sectores de la sociedad, ya que aunque los jóvenes son los usuarios más mayoritarios, no son los únicos que utilizan dichas redes. Otro aspecto destacable sería la necesidad de aumentar las consecuencias hacia las grandes empresas propietarias de las redes sociales, para que dejen de mirar a otro lado cuando estos problemas se les presentan.

También sería de utilidad, la implantación de educación sobre ética y derechos humanos a los informáticos, para que a pesar de que una Inteligencia Artificial produzca salidas no deseadas, éstas puedan reentrenarse de una manera más sencilla, gracias al conocimiento ético del que dispondrían los usuarios.

10.2 Trabajo futuro

Como parte de un posible trabajo futuro sería esencial la utilización de datos de usuarios reales de alguna red social para poder aumentar la validez de los resultados, ya que al ser los datos utilizados de origen, sintético hay errores respecto al orden de las preferencias de los usuarios respecto a ciertos contenidos. También se podrían hacer recomendaciones a partir de las categorías que indicase un algoritmo encargado para ello, en vez de tener que indicar a qué categorías pertenece un post manualmente. Sería interesante realizar una aplicación que permitiese bloquear o detectar contenido no deseado para adolescentes que pudiera mitigar el impacto de los anuncios a colectivos vulnerables como los adolescentes, similar a lo que tiene Apple en sus iPhone, pero dirigido hacia el resto de aplicaciones en su sistema operativo.

Bibliografía

- [1] J. Brailovskaia y T. Teichert, «“I like it” and “I need it”: Relationship between implicit associations, flow, and addictive social media use», *Computers in Human Behavior*, vol. 113, pág. 106 509, 2020, ISSN: 0747-5632. DOI: <https://doi.org/10.1016/j.chb.2020.106509>.
- [2] D.J. Kuss y M. D. Griffiths, «Social Networking Sites and Addiction: Ten Lessons Learned», *International Journal of Environmental Research and Public Health*, vol. 14, nº 3, 2017. DOI: [10.3390/ijerph14030311](https://doi.org/10.3390/ijerph14030311). dirección: <https://www.mdpi.com/1660-4601/14/3/311>.
- [3] O. Lopez-Fernandez, «Generalised Versus Specific Internet Use-Related Addiction Problems: A Mixed Methods Study on Internet, Gaming, and Social Networking Behaviours», *International Journal of Environmental Research and Public Health*, vol. 15, nº 12, 2018. DOI: [10.3390/ijerph15122913](https://doi.org/10.3390/ijerph15122913). dirección: <https://www.mdpi.com/1660-4601/15/12/2913>.
- [4] PEW Research Center, *Social Media Use in 2021*, Consultada el 11/07/2023, 2021. dirección: <https://www.pewresearch.org/internet/2021/04/07/social-media-use-in-2021/>.
- [5] M. Varona, A. Muela y J. Machimbarrena, «Problematic use or addiction? A scoping review on conceptual and operational definitions of negative social networking sites use in adolescents», *Addictive Behaviors*, vol. 134, pág. 107 400, 2022, ISSN: 0306-4603. DOI: <https://doi.org/10.1016/j.addbeh.2022.107400>.
- [6] E. C. M. Gámez-Guadix I. Orue, «Evaluation of the cognitive-behavioral model of generalized and problematic Internet use in Spanish adolescents Psicothema», *Psicothema*, vol. 23, págs. 299-306, 2013, ISSN: 0306-4603. DOI: <https://doi.org/10.7334/psicothema2012.274>.

- [7] G. Fioravanti, G. Flett, P. Hewitt, L. Rugai y S. Casale, «How maladaptive cognitions contribute to the development of problematic social media use», *Addictive Behaviors Reports*, vol. 11, pág. 100 267, 2020, ISSN: 2352-8532. DOI: <https://doi.org/10.1016/j.abrep.2020.100267>. dirección: <https://www.sciencedirect.com/science/article/pii/S2352853219302214>.
- [8] C. de la Hera, *Historia de las Redes Sociales: Cómo Nacieron yCuál fue su evolución* -, jun. de 2022. dirección: <https://marketing4ecommerce.net/historia-de-las-redes-sociales-evolucion/>.
- [9] M. Hemmings, «iPhone Photography For Dummies», en 1ª ed. For Dummies, 2020, cap. 1.
- [10] R. Fernández, *Usuarios Mundiales de las redes sociales líderes en 2023*, Última consulta 27 Mayo 2023, mayo de 2023. dirección: <https://es.statista.com/estadisticas/600712/ranking-mundial-de-redes-sociales-por-numero-de-usuarios/>.
- [11] R. Fernández, *Redes Sociales con más usuarios en España en 2021*, mayo de 2022. dirección: <https://es.statista.com/estadisticas/489153/porcentaje-de-internautas-en-las-redes-sociales-en-espana/>.
- [12] R. Fernández, *Edad de los usuarios de las Redes sociales en España*, Última consulta 27 Mayo 2023, nov. de 2022. dirección: <https://es.statista.com/estadisticas/1260093/redes-sociales-porcentaje-de-usuarios-por-edad-en-espana/>.
- [13] R. Fernández, *Redes sociales preferidas por la Generación Z en España*, Última consulta 27 Mayo 2023, mayo de 2023. dirección: <https://es.statista.com/estadisticas/873593/redes-sociales-preferidas-por-la-generacion-z-en-espana/>.
- [14] C. Gil, *Historia de Instagram, la app que revolucionó la forma de compartir Fotos Online - Marketing 4 ecommerce - tu revista de marketing online para E*, oct. de 2022. dirección: <https://marketing4ecommerce.net/historia-de-instagram-app/>.
- [15] S. Dixon, *Global: Instagram users 2018-2027*, mar. de 2023. dirección: <https://www.statista.com/forecasts/1138856/instagram-users-in-the-world>.
- [16] R. Fernández, *Instagram: Porcentaje de hombres y mujeres usuarios en el mundo en 2023*, mar. de 2023. dirección: <https://es.statista.com/estadisticas/875361/distribucion-por-genero-de-los-usuarios-mundiales-de-instagram/>.
- [17] A. Naveira, *Historia de twitter: Nacimiento y Evolución de una red social - marketing 4 ecommerce - tu revista de marketing online para E*, nov. de 2022. dirección: <https://marketing4ecommerce.net/historia-de-twitter/>.
- [18] J. Degenhard, *Global: Twitter users 2018-2027*, mar. de 2023. dirección: <https://www.statista.com/forecasts/1146722/twitter-users-in-the-world>.

- [19] S. Dixon, *Global twitter user distribution by gender 2022*, dic. de 2022. dirección: <https://www.statista.com/statistics/828092/distribution-of-users-on-twitter-worldwide-gender/>.
- [20] J. Ceci, *TikTok users worldwide 2027*, abr. de 2023. dirección: <https://www.statista.com/forecasts/1142687/tiktok-users-worldwide>.
- [21] L. Ceci, *Global tiktok user distribution by gender 2023*, mayo de 2023. dirección: <https://www.statista.com/statistics/1299785/distribution-tiktok-users-gender/>.
- [22] Instagram, *Shedding more light on how Instagram works*, jun. de 2021. dirección: <https://about.instagram.com/blog/announcements/shedding-more-light-on-how-instagram-works>.
- [23] S. McLachlan, *El Algoritmo de Instagram en 2022: Cómo lograr que tu contenido sea visto*, jun. de 2023. dirección: <https://blog.hootsuite.com/es/algoritmo-de-instagram/>.
- [24] Twitter, *About your for you timeline on Twitter*. dirección: <https://help.twitter.com/en/using-twitter/twitter-timeline>.
- [25] J. Hughes, *How the Twitter algorithm works in 2023*, jun. de 2023. dirección: <https://blog.hootsuite.com/twitter-algorithm/>.
- [26] C. Newberry, *2023 TikTok algorithm explained + tips to go viral*, feb. de 2023. dirección: <https://blog.hootsuite.com/tiktok-algorithm/>.
- [27] A. B. Goldman, A. P. Costello, A. C. Vaughan y A. H. Leggett, *Addictive potential of social media, explained*, mar. de 2023. dirección: <https://scopeblog.stanford.edu/2021/10/29/addictive-potential-of-social-media-explained/>.
- [28] L. Lanier, *Social Media Addiction Statistics*, Última consulta 17 Mayo 2023, 2023. dirección: <https://short.upm.es/zjyrl>.
- [29] K. Kircaburun y M. Griffiths, «Instagram addiction and the Big Five of personality: The mediating role of self-liking.», *Journal of behavioral addictions*, vol. 7, n° 1, págs. 158-170, 2018.
- [30] B. Foroughi, M. Griffiths, M. Iranmanesh e Y. Salamzadeh, «Associations Between Instagram Addiction, Academic Performance, Social Anxiety, Depression, and Life Satisfaction Among University Students», *International Journal of Mental Health and Addiction*, vol. 20, págs. 1-22, mar. de 2021. DOI: [10.1007/s11469-021-00510-5](https://doi.org/10.1007/s11469-021-00510-5).

- [31] T. Smith y A. Short, «Needs affordance as a key factor in likelihood of problematic social media use: Validation, latent Profile analysis and comparison of TikTok and Facebook problematic use measures», *Addictive Behaviors*, vol. 129, pág. 107 259, 2022, ISSN: 0306-4603. DOI: <https://doi.org/10.1016/j.addbeh.2022.107259>. dirección: <https://www.sciencedirect.com/science/article/pii/S0306460322000259>.
- [32] Comunidad de Madrid, *Prevención de adicciones*, oct. de 2022. dirección: <https://short.upm.es/5p46w>.
- [33] J. J. Carbonell Casasús, *¿Qué es una adicción?*, Y. Domínguez, ed., jun. de 2016. dirección: <https://www.topdoctors.es/diccionario-medico/adiccion#>.
- [34] P. Sha y X. Dong, «Research on Adolescents Regarding the Indirect Effect of Depression, Anxiety, and Stress between TikTok Use Disorder and Memory Loss», *International Journal of Environmental Research and Public Health*, vol. 18, n° 16, 2021. DOI: [10.3390/ijerph18168820](https://doi.org/10.3390/ijerph18168820). dirección: <https://www.mdpi.com/1660-4601/18/16/8820>.
- [35] M. Davis, *Tiktok is bad for your brain: Constant social media streaming narrows collective attention span, adversely affects mental health*, oct. de 2021. dirección: <https://www.sciencetimes.com/articles/34138/20211025/tiktok-bad-brain-constant-social-media-streaming-narrows-collective-attention.htm>.
- [36] A. Mekler, «The Effects of TikTok Use on College Student Learning», *Undergraduate Review*, vol. 16, n° 19, págs. 145-153, 2021.
- [37] Quanam, *Modelos de Recomendación: Recomendando Qué recomendar*, mayo de 2020. dirección: <https://quanam.com/modelos-de-recomendacion-recomendando-que-recomendar/#::~:~:text=A%5C%20modo%5C%20de%5C%20introducci%C3%B3n%5C%20la,dadas%5C%20por%5C%20los%5C%20distintos%5C%20usuarios..>
- [38] M. D. Pietro, *Modern recommendation systems with Neural Networks*, jun. de 2023. dirección: <https://towardsdatascience.com/modern-recommendation-systems-with-neural-networks-3cc06a6ded2c>.
- [39] F. Serradilla García, *Aprendizaje Automático. Redes de Neuronas*, Departamento de Inteligencia Artificial, mar. de 2019.
- [40] D. Mayerich, R. Sun y J. Guo, «Chapter Fifteen - Deep Learning», en *Microscope Image Processing (Second Edition)*, F. A. Merchant y K. R. Castleman, eds., Second Edition, Academic Press, 2023, págs. 431-456, ISBN: 978-0-12-821049-9. DOI: <https://doi.org/10.1016/B978-0-12-821049-9.00015-0>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780128210499000150>.
- [41] Google, *Preguntas frecuentes*, Colaboratory. dirección: <https://short.upm.es/edqgz>.

- [42] European Union, *Reglamento General de Protección de Datos (RGPD)*, ene. de 2022. dirección: <https://eur-lex.europa.eu/ES/legal-content/summary/general-data-protection-regulation-gdpr.html>.
- [43] Google, *Filtrado Basado en el contenido*; *Machine learning*; *Google for developers*, sep. de 2022. dirección: <https://developers.google.com/machine-learning/recommendation/content-based/basics?hl=es-419>.
- [44] A. González, *Sistemas de Recomendación de Contenido Con Machine Learning*. dirección: <https://cleverdata.io/sistemas-recomendacion-machine-learning/>.
- [45] IBM, *True positive rate in Watson OpenScale quality metrics*, COnsultada el 08/07/23, 2023. dirección: <https://www.ibm.com/docs/en/cloud-paks/cp-data/4.7.x?topic=metrics-true-positive-rate-tptr>.
- [46] N. Craswell, «Mean Reciprocal Rank», en *Encyclopedia of Database Systems*, L. LIU y M. T. ÖzSU, eds. Boston, MA: Springer US, 2009, págs. 1703-1703, ISBN: 978-0-387-39940-9. DOI: [10.1007/978-0-387-39940-9_488](https://doi.org/10.1007/978-0-387-39940-9_488). dirección: https://doi.org/10.1007/978-0-387-39940-9_488.
- [47] D. Fusaro, *Las Redes Sociales Nos Están alienando cada vez más y nos convierten en “egomonstruos”...* Sep. de 2020. dirección: <https://latribunadelpaisvasco.com/art/13825/las-redes-sociales-nos-estan-alienando-cada-vez-mas-y-nos-convierten-en-egomonstruos>.
- [48] J. Orlowski, *The Social Dilemma*, 2020.
- [49] M. C. Mercado, K. Holland, R. W. Leemis, D. M. Stone y J. Wang, «Trends in Emergency Department Visits for Nonfatal Self-inflicted Injuries Among Youth Aged 10 to 24 Years in the United States, 2001-2015», *JAMA*, vol. 318, n° 19, págs. 1931-1933, nov. de 2017, ISSN: 0098-7484. DOI: [10.1001/jama.2017.13317](https://doi.org/10.1001/jama.2017.13317). eprint: https://jamanetwork.com/journals/jama/articlepdf/2664031/jama_mercado_2017_ld_170039.pdf. dirección: <https://doi.org/10.1001/jama.2017.13317>.
- [50] Psonríe, *Dismorfia corporal y redes sociales: Cómo las redes sociales afectan a la Percepción de Uno Mismo*. dirección: <https://www.psonrie.com/noticias-psicologia/dismorfia-corporal-y-redes-sociales-como-las-redes-sociales-afectan-a-la-percepcion-de-uno-mismo>.
- [51] D. Domínguez, *La Editora del Diario de Vox Que difundió El Bulo racista sobre el asesino de tirso de molina recibió 220.000 Euros de dinero público entre 2021 Y 2022*, jul. de 2023. dirección: <https://www.lamarea.com/2023/07/05/editora-diario-vox-bulo-racista-asesino-tirso-molina-dinero-publico/>.

- [52] P. Peiró, *Dos Delincuentes Habituales del Centro de Madrid, Detenidos por matar a conchi, La Comerciante de Tirso de Molina*, jul. de 2023. dirección: <https://elpais.com/espana/madrid/2023-07-04/detenido-el-presunto-asesino-de-conchi-la-comerciante-de-tirso-de-molina-acuchillada-en-su-tienda.html>.
- [53] Wikipedia, *Pizzagate*, jun. de 2023. dirección: <https://es.wikipedia.org/wiki/Pizzagate>.
- [54] C. Planas Bou, *La manipulación Política Se Propaga en facebook*, sep. de 2020. dirección: <https://www.elperiodico.com/es/sociedad/20200915/manipulacion-politica-propaga-facebook-desinformacion-8113585>.
- [55] J. P. Colomé, *Facebook admite en documentos internos que instagram es tóxico para Muchas Adolescentes*, sep. de 2021. dirección: <https://elpais.com/tecnologia/2021-09-15/facebook-admite-en-documentos-internos-que-instagram-perjudica-la-autoestima-de-muchas-jovenes.html>.
- [56] M. Terán Haughey, *Multa Histórica de 1.200 millones a Facebook por violar la política de protección de datos de la ue*, mayo de 2023. dirección: <https://www.eleconomista.es/tecnologia/noticias/12285863/05/23/multa-historica-de-1200-millones-a-facebook-por-violar-la-politica-de-proteccion-de-datos-de-la-ue.html>.
- [57] V. Vishwarupea, P. Joshib, N. Mathiasc, S. Maheshwarid, S. Mhaisalkard y V. Paward, «Explainable AI and Interpretable Machine Learning: A Case Study in Perspective.», *Procedia Computer Science*, vol. 204, págs. 869-876, 2022. DOI: <https://doi.org/10.5853/jos.2017.02054>.
- [58] M. Awad y R. Khanna, «Machine Learning», en *Efficient Learning Machines: Theories, Concepts, and Applications for Engineers and System Designers*. Berkeley, CA: Apress, 2015, págs. 1-18, ISBN: 978-1-4302-5990-9. DOI: [10.1007/978-1-4302-5990-9_1](https://doi.org/10.1007/978-1-4302-5990-9_1). dirección: https://doi.org/10.1007/978-1-4302-5990-9_1.
- [59] NIMH, *Trastorno de Ansiedad Social: Más allá de la simple Timidez*, 2022. dirección: https://www.nimh.nih.gov/health/publications/espanol/trastorno-de-ansiedad-social-mas-alla-de-la-simple-timidez#part_6293.
- [60] S. Sinharay, «An Overview of Statistics in Education», en *International Encyclopedia of Education (Third Edition)*, P. Peterson, E. Baker y B. McGaw, eds., Third Edition, Oxford: Elsevier, 2010, págs. 1-11, ISBN: 978-0-08-044894-7. DOI: <https://doi.org/10.1016/B978-0-08-044894-7.01719-X>. dirección: <https://www.sciencedirect.com/science/article/pii/B978008044894701719X>.

- [61] S. Oswalt Manoj, J. Ananth, M. Rohini, B. Dhanka, N. Pooranam y S. Ram Arumugam, «17 - FWS-DL: forecasting wind speed based on deep learning algorithms», en *Artificial Intelligence for Renewable Energy Systems*, ép. Woodhead Publishing Series in Energy, A. K. Dubey, S. K. Narang, A. L. Srivastav, A. Kumar y V. García-Díaz, eds., Woodhead Publishing, 2022, págs. 353-374, ISBN: 978-0-323-90396-7. DOI: <https://doi.org/10.1016/B978-0-323-90396-7.00007-9>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780323903967000079>.
- [62] V. Kotu y B. Deshpande, «Chapter 11 - Recommendation Engines», en *Data Science (Second Edition)*, V. Kotu y B. Deshpande, eds., Second Edition, Morgan Kaufmann, 2019, págs. 343-394, ISBN: 978-0-12-814761-0. DOI: <https://doi.org/10.1016/B978-0-12-814761-0.00011-3>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780128147610000113>.
- [63] Instagram, *Instagram feed: Create content posts and inspire your community*. dirección: <https://business.instagram.com/instagram-feed>.
- [64] R. Terrasa y V. Hernández, ¿Qué es la Generación Z? Dirección: <https://lab.elmundo.es/generacion-z/que-es.html>.
- [65] B. P. Woolf, «Chapter 7 - Machine Learning», en *Building Intelligent Interactive Tutors*, B. P. Woolf, ed., San Francisco: Morgan Kaufmann, 2009, págs. 221-297, ISBN: 978-0-12-373594-2. DOI: <https://doi.org/10.1016/B978-0-12-373594-2.00007-1>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780123735942000071>.
- [66] Arimetrics, *Qué Es millenial - definición, Significado y Ejemplos*, abr. de 2023. dirección: <https://www.arimetrics.com/glosario-digital/millenial>.
- [67] D. Ortiz, *Instagram reels: Qué Es, cómo funciona y se Crean vídeos*. dirección: <https://www.cyberclick.es/numerical-blog/instagram-reels-que-es-como-funciona-y-se-crean-videos>.
- [68] J. Han, M. Kamber y J. Pei, «2 - Getting to Know Your Data», en *Data Mining (Third Edition)*, ép. The Morgan Kaufmann Series in Data Management Systems, J. Han, M. Kamber y J. Pei, eds., Third Edition, Boston: Morgan Kaufmann, 2012, págs. 39-82, ISBN: 978-0-12-381479-1. DOI: <https://doi.org/10.1016/B978-0-12-381479-1.00002-2>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780123814791000022>.
- [69] GCFGlobal, ¿Cómo USAR instagram?: ¿Qué son y para qué sirven las historias de instagram? Dirección: [https://edu.gcfglobal.org/es/como-usar-instagram/que-son-y-para-que-sirven-las-historias-de-instagram/1/#::~text=Las%](https://edu.gcfglobal.org/es/como-usar-instagram/que-son-y-para-que-sirven-las-historias-de-instagram/1/#::~text=Las%20historias%20de%20instagram%20sirven%20para%20mostrar%20momentos%20importantes%20de%20nuestra%20vida)

20historias%20de%20Instagram%20son, historias%20son%20eliminadas%20del%20perfil..

- [70] Google, *Clasificación: Verdadero o falso y positivo O negativonbsp; /nbsp; machine learningnbsp; /nbsp; google for developers*, sep. de 2022. dirección: <https://developers.google.com/machine-learning/crash-course/classification/true-false-positive-negative?hl=es-419>.

Glosario

Accuracy Tasa de predicciones correctas (o incorrectas) realizadas por el modelo sobre un conjunto de datos [58]. 39

Ansiedad social Una persona con trastorno de ansiedad social siente síntomas de ansiedad o temor en situaciones en las que otros pueden estar analizándolos, evaluándolos o juzgándolos, como al hablar en público, conocer gente nueva, salir con alguien en una cita, asistir a una entrevista de trabajo, responder una pregunta en clase, o tener que hablar con un cajero en una tienda. Hacer cosas rutinarias, como comer o beber frente a otras personas o usar un baño público, también le puede causar ansiedad o temor debido a la preocupación de ser humillado, juzgado o rechazado [59]. 25

Análisis de grupos Técnica para agrupar observaciones similares en una serie de clústeres basándose en los valores observados de varias variables para cada individuo. [60]. 35

Error Absoluto Medio la varianza media entre los valores significativos del conjunto de datos y los valores proyectados del mismo conjunto de datos.[61]. 42

Factorización de matrices Técnica para descubrir los factores ocultos a partir de la matriz de valoraciones y asignar los ítems y los usuarios en función de dichos factores. [62]. 35

Feed de Instagram destino optimizado para dispositivos móviles donde las personas pueden compartir fotos y vídeos, conectarse con su comunidad y explorar el contenido que les interese. El contenido se muestra haciendo scroll en vertical y permite interactuar con las publicaciones del resto de usuarios [63]. 13

Generación Z Generación comprendida entre finales de 1990 y los 2000 [64]. 6

Hashtag Conjunto de caracteres precedidos por una almohadilla (#) que sirve para identificar o etiquetar un mensaje en las redes sociales. 8

Machine Learning El aprendizaje automático (AA) o aprendizaje automatizado o aprendizaje de máquinas o aprendizaje computacional (del inglés, machine learning) es el subcampo de las ciencias de la computación y una rama de la inteligencia artificial, cuyo objetivo es desarrollar técnicas que permitan que las computadoras adquirir e integrar conocimientos a través de observaciones a gran escala, y para mejorar y ampliarse a sí mismo mediante el aprendizaje de nuevos conocimientos en lugar de ser programado con esos conocimientos. [65].

34

Millenials Generación comprendida entre primeros de la década de 1980 y mediados de 1990 [66]. 5, 7

Rango Recíproco Medio La medida de recuperación de información de rango recíproco (RR) calcula el recíproco del rango en el que se recuperó el primer documento relevante. El rango recíproco es 1 si un documento relevante se ha obtenido en el rango 1, 0,5 si un documento relevante se ha obtenido en el rango 2 y así sucesivamente. Cuando se hace la media de las consultas, la medida se denomina rango recíproco medio (MRR).[46]. 39

Reel Son vídeos de corta duración en formato vertical de Instagram a las cuales se les pueden poner filtros o música [67]. 8

Similitud de coseno La similitud del coseno mide la similitud entre dos vectores de un espacio de producto interior. Se mide por el coseno del ángulo entre dos vectores y determina si dos vectores apuntan aproximadamente en la misma dirección [68]. 35

Smartphone Teléfono celular con pantalla táctil, que permite al usuario conectarse a internet, gestionar cuentas de correo electrónico e instalar otras aplicaciones y recursos a modo de pequeño computador.. 5

Stories Son contenidos audiovisuales de Instagram en formato 9:16 que tienen una duración determinada de 24 horas [69]. 8

True Positive Un verdadero positivo es un resultado en el que el modelo predice correctamente la clase positiva [70]. 39

Tweet Mensaje de texto de hasta 140 caracteres, aunque actualmente la limitación es hasta 280. También se puede incluir contenido multimedia como fotos, vídeos o encuestas.. 10

