

Sistemas de recomendación en plataformas de streaming audiovisual: las lógicas de los algoritmos

Sistemas de recomendação em plataformas de streaming audiovisual: a lógica dos algoritmos

Recommendation systems in video streaming platforms: the logics of algorithms

Mariano Zelcer¹

Resumen

Una de las novedades que trajeron las plataformas de *streaming* audiovisual son los sistemas de recomendación, que les brindan a los usuarios sugerencias acerca de qué contenidos consumir a partir de la consideración de múltiples variables, entre ellas, la historia de los consumos de ese mismo usuario. Estas recomendaciones son realizadas generalmente por algoritmos de *machine learning*, y dan como resultado una suerte de curaduría automatizada de los contenidos, que determinan en buena medida los consumos cotidianos de producciones audiovisuales. Este trabajo busca caracterizar algunas de las lógicas que guían esos algoritmos desde una perspectiva semiótica. Hacia el cierre, se discute cuáles son, en estos sistemas que parecen tender siempre a proponer consumos similares a los ya realizados, los espacios para la novedad.

Palabras clave: plataformas; sistemas de recomendación; algoritmos; machine learning; curaduría.

Resumo

Uma das novidades associadas à expansão das plataformas de *streaming* audiovisual são os sistemas de recomendação. Esses sistemas fornecem aos usuários sugestões sobre quais conteúdos consumir com base na consideração de múltiplas variáveis, que incluem o histórico de consumo desse mesmo usuário. Essas recomendações são feitas geralmente por algoritmos de *machine learning* e resultam em uma espécie de curadoria automatizada dos conteúdos, que determinam em grande parte o consumo diário de produções audiovisuais. Este trabalho busca caracterizar algumas das lógicas que orientam a atividade desses algoritmos a partir de uma perspectiva semiótica. No

¹ Doutor em Comunicação. Professor de Semiótica e de Teorias da Comunicação na Universidade Nacional de las Artes (UNA/Buenos Aires, Argentina). E-mail: marianozelcer@yahoo.com.ar - ORCID: [/0000-0001-7472-0906](https://orcid.org/0000-0001-7472-0906)



final, discute-se quais são, nesses sistemas que sempre parecem tender a propor consumos semelhantes aos já realizados, os espaços para a novidade.

Palavras-chave: plataformas; sistemas de recomendação; algoritmos; machine learning, curadoria.

Abstract

One of the novelties associated with the expansion of audiovisual streaming platforms are recommendation systems, which provide users with suggestions about which content they should consume. These suggestions are done considering multiple variables, which include the consumption history of that specific user, among others. In many cases, these recommendations are made by machine learning algorithms, and result in a sort of automated curation of the contents, which largely determine the daily consumption of audiovisual productions. This work seeks to characterize some of the logics that guide the activity of these algorithms from a semiotic perspective. Towards the end of the work, it is discussed which are the spaces for novelty, in these systems that always seem to propose consumptions similar to those already carried out.

Keywords: platforms; recommendation systems; algorithms; machine learning, curation.

Introducción

El presente trabajo se enmarca en una investigación que se propone indagar acerca del funcionamiento de los algoritmos de *machine learning* en la selección y organización de contenidos en algunas de las principales plataformas contemporáneas de *streaming* como Netflix, Spotify o YouTube, que están cambiando radicalmente los modos en que se consumen los productos auditivos y audiovisuales en la vida cotidiana. En el caso de la imagen audiovisual, los flujos audiovisuales de la cotidianidad se concentraban, durante la época de mayor predominio de los medios masivos, principalmente en la televisión. Como es sabido, en este medio, el espectador puede elegir el canal que desea ver; luego, la programación que se ve allí es la misma para todos aquellos que sintonicen esa señal: se construía así una socialidad compartida. El peso de la televisión en la construcción de lo real social (VERÓN, 1987) fue determinante en la segunda mitad del siglo XX, con pocas emisoras que reunían altos niveles de *rating* (CARLÓN, 2016). En el momento actual de la mediatización, caracterizado por la fuerte presencia del sistema de medios con base en Internet, el panorama es radicalmente diferente: si bien la televisión sigue vigente, una parte cada



vez mayor de los consumos audiovisuales cotidianos se produce en un conjunto de plataformas de *streaming* (*YouTube, Amazon Prime, Netflix, etc.*). En ellas, habitualmente el usuario elige al inicio algunos textos² para ver; luego, a partir de estos primeros consumos, intervienen sistemas de recomendación que realizan sugerencias acerca de qué otros productos audiovisuales podrían consumirse. En muchos casos, como YouTube, el *autoplay* recrea un flujo continuo de imágenes, pero ahora con una selección de videos personalizada que, presumiblemente, responde a las preferencias del usuario.

En este artículo nos proponemos acercarnos a estos sistemas de recomendación desde una semiótica entendida como una lógica, viendo los aportes que la perspectiva de Charles Sanders Peirce puede brindar para su comprensión. En nuestro análisis, pondremos el foco en YouTube, aunque buena parte de las observaciones resultará válida para los sistemas de recomendación de otras plataformas.

Los sistemas de recomendación

Comencemos por definir qué es un sistema de recomendación. Este tipo de sistema puede entenderse como “un dispositivo que consiste en una base informática de obtención y procesamiento de datos sobre lo que los usuarios hacen en la Red [o dentro de una plataforma determinada], y que [mediante la intervención de algoritmos] vuelve como generador de ‘atajos’ para facilitar el encuentro de cada usuario con aquello que podría interesarle” (CINGOLANI, 2017a, p.32). Los sistemas de recomendación tienen la particularidad de realimentarse a partir de la actividad de los usuarios; tienen, al decir de Cingolani, a los “usuarios en el centro”. Sin embargo, los “atajos” de estos sistemas no siempre nos conducen a un lugar que ya tenemos definido de antemano. Las sugerencias del sistema de recomendación pueden llevarnos a múltiples lugares: puede ser uno que teníamos en mente, o alguno que ya hubiéramos visitado (como las opciones de “Volver a escuchar”); pero también nos pueden guiar hacia lugares novedosos en los que no hayamos estado nunca antes (aunque probablemente sean similares en algunos aspectos a los que ya conocíamos). En ese sentido, los algoritmos que operan en los sistemas de recomendación realizan tareas de selección, clasificación y organización de contenidos, que aquí proponemos conceptualizar como una *curaduría automatizada*. La incidencia de los algoritmos en las pantallas de inicio de

² Empleamos aquí la noción de “texto” en un sentido amplio, como lo entiende Eliseo Verón (1996); así, tanto una película como una serie en cualquier formato audiovisual son consideradas “textos”.



las plataformas de contenidos (FERNÁNDEZ, 2018) es variable. Se pueden identificar, al menos, tres tipos de selección de operando allí: en primer lugar, algoritmos de selección de contenidos que no implican aprendizaje ni personalización (por ejemplo: “lo más nuevo”, “lo más visto”, etc.); en segundo lugar, listados personalizados que habitualmente implican algún tipo de aprendizaje en el tiempo: son los algoritmos de *machine learning* que registran y procesan información de las actividades del usuario en conjunto con otros datos para generar las recomendaciones. Finalmente, hay selecciones de contenidos que no han sido definidas necesariamente por un algoritmo: se trata de procesos de selección editorial realizados por humanos que coexisten con recomendaciones automatizadas.

Los trabajos de Cingolani parten de la constatación de una proliferación de artículos centrados en el aspecto informático del funcionamiento de estos sistemas, centrados en los algoritmos, y toman un partido explícito, que el autor desarrolla con agudeza: no ocuparse de este plano, sino de las propuestas enunciativas que se despliegan efectivamente en esas superficies textuales: “Más allá del tipo de procesamiento de datos que cada sistema de recomendación haga, nos interesa la organización enunciativa de los sitios” (CINGOLANI, 2017b, p.11).

Como adelantamos, en este trabajo pretendemos tomar un camino complementario, y preguntarnos justamente por los algoritmos, aunque ahora desde una mirada que incluye la perspectiva semiótica. Dentro de los distintos tipos de algoritmos, nos detendremos sobre aquellos que operan por *machine learning*, o aprendizaje automático por computadoras, y que tienen incidencia en la selección y organización de contenidos que realizan los sistemas de recomendación, recordando siempre que –como vimos– el conjunto de recomendaciones que presenta cada plataforma no se explica exclusivamente por este tipo de funcionamientos.

Las plataformas de contenidos

Volvamos ahora a las plataformas de *streaming*. Sin pensar aún en los sistemas de búsqueda o recuperación de su acervo, podemos preguntarnos si cada uno de los contenidos (audios, videos, etc.) que está dentro de cada plataforma está catalogado de acuerdo con uno o más sistemas clasificatorios (género, estilo, etc.) o si se encuentra indexado mediante palabras clave que lo describen, y que pueden no tener ninguna sistematicidad entre ellas (como título, autor, contenido, etc.). Esta pregunta no se



puede responder con precisión en pocas líneas y para todas las plataformas por igual, pero sí podemos señalar algunas cuestiones generales:

1. Las plataformas suelen combinar ambos mecanismos. Además, cada “registro” (cada video, cada audio) puede estar inscripto en una o más categorías (por ejemplo “infantil” y “animación”);
2. Puede haber asociados a esos registros otros datos que no se correspondan con una “categoría”, sino con una “cualidad” (por ejemplo, “contiene escenas de violencia”, “blanco y negro”, u “obra de sólo piano”), que en ocasiones puede funcionar como categoría. Es decir, lo que semióticamente puede funcionar en dos niveles muy distintos (un género es una clasificación social que agrupa un tipo de textos,³ un rasgo es una propiedad significativa⁴ que no conlleva ni implica, de entrada, ningún tipo de clasificación), en términos de una base de datos puede manejarse a un mismo nivel de “etiquetas” (así, “comedia romántica” puede ser una etiqueta, y “efectos estroboscópicos” otra). Es interesante notar que, si bien la presencia de un rasgo específico (como la presencia del piano en una obra musical) puede funcionar como clasificación (“obras en las que hay piano”), ese conjunto recortado no es necesariamente sistemático con otros (sólo se opone a su contrario: las obras que no contienen piano);
3. Puede haber asociadas otras frases o palabras clave que nada tengan de sistemático, y que, sin embargo, hablen de la obra (como el título de la obra, o su descripción; típicos casos de metadatos);
4. A los datos, por así decirlo, intrínsecos de la obra (aquellos que podrían determinarse aún antes de que se incorporara al acervo de la plataforma), se les suman muchos otros que tienen que ver con *su historia como objeto de consumo*. Por ejemplo:
 - Cuántas veces fue vista o reproducida, o en qué medida es reproducida en su totalidad, y en qué medida abandonada;
 - Qué calificación tuvo en sus sistemas de puntuación;
 - En conjunto con qué otras obras fue consumida;
 - Qué usuarios la consumieron.

³ Estamos siguiendo aquí la definición de Oscar Steimberg (1993).

⁴ Empleamos esta noción como lo hace Eliseo Verón (1996).



Desde luego, mientras que los datos intrínsecos se mantienen invariables en el tiempo, los demás pueden ir variando, porque se modifican a medida que la obra es reproducida (escuchada, vista) una y otra vez.⁵

Como es fácil imaginar, un funcionamiento de este tipo genera una enorme cantidad de datos por cada obra, en un funcionamiento típico del *big data*. Mientras que el volumen de datos intrínsecos de cada obra permanece relativamente estable, el relacionado con la historia de sus consumos tiende a crecer con el tiempo.

En forma complementaria, se generan también datos asociados a los usuarios de las plataformas. De un modo similar al de las obras, los usuarios también tienen unos pocos datos intrínsecos (el nombre de usuario, el país, la fecha de nacimiento, el sexo, etc.), y la plataforma va enriqueciendo, con sus consumos, su perfil.⁶

Los algoritmos de *machine learning*

Esta rápida descripción del modo en el que las plataformas almacenan la información de las obras y sus usuarios nos permitirá describir algunos funcionamientos de los algoritmos de *machine learning* en los sistemas de recomendación. Desarrollaremos esta discusión a partir de un caso de YouTube, que ilustrará diversos aspectos del fenómeno que queremos presentar. Lo trabajaremos a través de tres entradas analíticas, que abordarán respectivamente:

- El nivel de los hechos, dando cuenta de lo observado, aun sin presentar ninguna explicación o interpretación;
- Las lógicas que intervinieron y que explican el funcionamiento observado en el algoritmo, atendiendo a presupuestos e hipótesis;
- Las lógicas semióticas, entendidas como tipos de razonamiento, que están implicadas en estos mismos funcionamientos.

⁵ En términos informáticos, es probable que buena parte de esta información no se guarde como una propiedad de las obras, sino de sus consumos. Así, podemos imaginar (al menos) dos tablas con datos en relación con las obras: la de las obras en sí mismas, con los datos intrínsecos, y la de sus consumos, con información acerca de cada vez que la obra fue vista o reproducida; se incluiría allí también la información acerca de quién es el usuario que la ha visto.

⁶ De igual modo, no estamos describiendo aquí la estructura de la base de datos, en la que probablemente la información de usuarios y de consumos se almacene en tablas separadas, sino el tipo de información del que dispone la plataforma, en la que hay asociado a cada usuario una historia de sus consumos.



El nivel de los hechos

El ejercicio es simple: ingresamos en nuestro navegador web en “modo de incógnito”, lo que hace que no se considere ningún historial ni antecedente de navegación, y vamos a YouTube, directamente a un video en el que la artista de origen coreano Sangah Noona toca versiones instrumentales de distintas canciones de The Beatles en piano.⁷ A la derecha del video aparece una serie de recomendaciones con miniaturas, para elegir por qué videos continuar eventualmente la navegación. Encontramos allí:

- Otros videos de Sangah Noona tocando temas de The Beatles en el piano
- Un video de versiones “relajantes” en guitarra acústica de temas de The Beatles
- Un video de un tributo sinfónico, también con temas de The Beatles
- Un video que tiene los temas de un CD del músico coreano Yiruma, también pianista; en este caso los temas no son de The Beatles, sino propios.
- Un video con versiones “relajantes” en piano de canciones de Disney.
- Un video con el álbum “Piano plays to Queen”, con versiones instrumentales en piano de canciones de Queen.
- Finalmente, el último video que se ve sin hacer *scroll* incluye también versiones en piano de The Beatles, en este caso, de la pianista japonesa Saya.

Luego de escuchar durante un rato a Noonah, cliqueamos en la miniatura que nos lleva al video del “tributo sinfónico” a The Beatles. Ahora las recomendaciones para seguir viendo videos cambian: aparecen, entre otros, videos con versiones en vivo de The Beatles, otras orquestas que tocaron temas de The Beatles, y otras orquestas sinfónicas, tocando un repertorio que no es de The Beatles. Escuchamos unos minutos del “tributo sinfónico” y damos por finalizado nuestro ejercicio.

Nos conformamos, en este caso, con esta somera descripción: no abordaremos aquí un análisis discursivo, porque el centro de nuestra indagación en este trabajo está justamente en la identificación y caracterización de las lógicas, de las que nos ocuparemos en los dos apartados que siguen.

⁷ Ver <https://bit.ly/3jYmcNB>. Consulta: 12 ene. 2023.



Las lógicas del algoritmo

¿Cómo pueden explicarse las recomendaciones que brindó el algoritmo⁸ a partir del video elegido? Los sistemas de recomendación trabajan con múltiples presupuestos. Explicitemos dos de ellos:

1. *El consumo como indicio de los gustos*: si el usuario 1 ve el video A, es porque le gusta (puesto que no habría razón para que lo hiciera si no fuera así). De aquí se desprende como corolario que el video A puede ser tomado como referencia, al menos en principio, para realizar recomendaciones, sin necesidad de que el usuario haya hecho una acción explícita de declaración de su gusto por esa obra (como un “me gusta”, o la asignación de una calificación positiva).
2. *Las propiedades o categorías de los textos como explicación, al menos parcial, de los gustos*: a los usuarios les gustan los textos porque tienen ciertas propiedades, o porque se inscriben dentro de ciertas categorías (pero en ese caso, seguramente se inscriban por tener ciertas propiedades). De aquí se desprende como corolario que las recomendaciones que se realicen deberían ser de otros textos que compartan algunas propiedades, o que se inscriban en las mismas categorías que los que ya les han gustado.

Además de estos presupuestos, hay también cuatro hipótesis o presunciones que guían la actividad de los algoritmos.

3. *La relativa estabilidad en los gustos*: si al usuario 1 le ha gustado recientemente la obra A porque es del tipo X (o porque posee el rasgo X, o está “etiquetado” como X)⁹, entonces la obra B, que es del tipo X (o posee el rasgo X), probablemente también le gustará. De aquí se desprende que, si la obra B no le gusta al usuario, entonces la obra A no le había gustado por ser del tipo X (o por poseer el rasgo X), sino por alguna otra pertenencia o rasgo.

⁸ Es probable que, en los hechos, haya intervenido más de un algoritmo en la generación de estas recomendaciones. Por una cuestión de simplicidad, nos referiremos aquí al algoritmo en singular, dando cuenta eventualmente de sus diversos funcionamientos.

⁹ Ignacio Uman explica que, en el caso de Netflix, hay un proceso de indexación que implica la intervención de una persona: el “etiquetador”, que les añade *tags* o etiquetas “manualmente” a los contenidos (UMAN, 2018). En el mismo texto, Uman refiere una entrevista a Chris Jaffe, vicepresidente de innovación de Netflix, que explica la tarea de los etiquetadores: “son generalmente guionistas, directores y críticos que catalogan los contenidos de Netflix en 150 categorías creadas justamente para que el algoritmo funcione mejor y pueda recomendar más precisamente”. El artículo citado se puede ver en <https://bit.ly/3kogo9YS>. Consulta: 12 ene. 2023.



4. *La multiplicidad de los gustos*: habitualmente, a un mismo usuario le gustan textos de más de un tipo / caracterizados por más de un rasgo. De esto se desprende que el hallazgo de una categoría o una “etiqueta” que le gusta al usuario no invalida que aparezcan otras que también sean de su preferencia.

5. *La existencia de afinidad en los gustos de los distintos usuarios*: esta hipótesis es de otro orden, y puede formularse como sigue: si al usuario 1 le gustan las obras de los tipos X e Y, y al usuario 2 le gustan las obras de tipo X, es probable que al usuario 2 también le gusten las obras del tipo Y. Desde aquí se puede regresar al tercer supuesto, y considerar un que, en conjunto con esta hipótesis, conforman un entimema, como si se tratara de dos premisas. La conclusión podría formularse como sigue: Si al usuario 1 le gusta la obra A, que es del tipo X, probablemente le gusten las obras del tipo Y (puesto que a los usuarios que les gustan las obras del tipo X, suelen gustarles las del tipo Y).

Estas hipótesis operan también habitualmente en la vida cotidiana, pero es bueno explicitarlas, porque explican el funcionamiento lógico de los algoritmos. Deseamos añadir una más, probablemente más alejada de lo que puede pensarse espontáneamente:

6. *La existencia de correlaciones de cierta estabilidad entre el consumo de obras*. Hay obras que son consumidas con otras obras, con las que forman series o conjuntos. Esta hipótesis de algún modo comprende la anterior, aunque, por el grado de generalidad en su formulación, la excede, dado que dos textos pueden consumirse en conjunto por múltiples razones, y no solamente por ser del mismo tipo: podría ser, por ejemplo, porque son contemporáneos, porque son del mismo artista, porque son versiones de una misma obra, porque comparten un estilo, porque se corresponden con una película y su secuela, porque son de artistas de una misma ideología, etc. Nos interesa presentarla aquí por dos razones: por un lado, porque, así como se formula, se desentiende de los usuarios (aunque los supone: si dos obras son consumidas en conjunto, es porque hay usuarios que las consumen de ese modo). Por el otro, porque es la que mejor explica ciertos funcionamientos del *deep learning*, como el que muchas veces tienen los algoritmos conocidos como “redes neuronales”.

Regresemos ahora al caso que nos ocupa. Comenzamos nuestra navegación en la plataforma “sin historia”, y vimos un video musical que puede pensarse en la



intersección de múltiples categorías y “clases”, derivadas de sus distintas propiedades “etiquetadas”. Podemos pensar, al menos, en las cuatro siguientes:

- Versiones/*covers* en piano;
- Versiones/*covers* instrumentales de The Beatles;
- Pianistas coreanos;
- Pianistas de países orientales.

Revisemos el listado de presupuestos: el algoritmo presupone que se ha escogido el video de Sangah Noona porque es del gusto del usuario (presupuesto 1). Este video se habrá elegido porque posee al menos una propiedad, o se inscribe en alguna categoría, que es del gusto del usuario (presupuesto 2). El algoritmo identifica la pertenencia de este video a por lo menos cuatro clases o categorías, que hemos enumerado recién. Es decir, como estamos en un “momento cero”, no puede decidir si al usuario le gusta este video porque contiene *covers* en piano, porque los temas son de The Beatles, porque la pianista es coreana, por alguna combinación de estos factores, o por alguna otra categoría/explicación (por ejemplo, porque al usuario le gusta Sangah Noona). Ese listado organizado y priorizado, sin embargo, ya es seguramente el resultado de lo que el algoritmo ha aprendido con otros usuarios que han visto videos como éste o similares, y por ello brinda estas recomendaciones en primer lugar.

¿Cómo puede explicarse el funcionamiento del algoritmo? Recordemos, antes de avanzar, que, desde un punto de vista informático, un algoritmo es “un conjunto de instrucciones definidas, ordenadas y acotadas para resolver un problema, realizar un cálculo o desarrollar una tarea” (MALUENDA DE VEGA, 2021; BAZZARA, 2021). Todos poseen tres partes:

- La entrada o *input*, con la que el algoritmo va a trabajar para alcanzar la solución que se espera;
- El *proceso*, que es específicamente el conjunto de pasos o instrucciones para llegar, a partir de la entrada, a la salida, también conocida como *output*. Esta secuencia no es necesariamente lineal: puede haber reglas, condiciones y hasta meta-reglas que pueden introducir variaciones en ese proceso;
- Y finalmente, un *output* o *salida*, que presenta resultados.



El *input* en este caso ha sido el video específico seleccionado; el proceso es para nosotros inaccesible, pero tenemos algunos indicios de lo que ha realizado el algoritmo: “ubicó” ese video en un entramado de categorías y clasificaciones, y generó como *output* una recomendación con otras obras que abarcan, al menos, cuatro de ellas (si sólo miramos la primera vista de la pantalla, sin hacer *scrolling* hacia abajo). Ahora bien, estamos poniendo el foco aquí en los algoritmos de *machine learning* o “aprendizaje automatizado”. ¿Cómo se puede observar el aprendizaje en este caso? Como se recordará, la navegación dentro de la plataforma continuó con un clic para ver el video del tributo sinfónico a The Beatles. Ese clic es interpretado por el algoritmo como un nuevo indicio de gusto o interés (presupuesto 1), y también como una primera definición: si, ante las opciones, el usuario no eligió escuchar *covers* de piano, ni ningún otro pianista, sino nuevas versiones de The Beatles... entonces probablemente le gusten los *covers*, y/o le gusten The Beatles (presupuesto 2). Las nuevas recomendaciones incluyen entonces al conjunto original The Beatles cantando, así como otras versiones instrumentales (presupuesto 3); y también otros videos de orquestas (puesto que es probable que al usuario también le gusten las orquestas, cosa que recién podrá aprender si en algún momento el usuario genera alguna acción que así lo indique, como ver otros videos de orquestas; hipótesis 4). De igual modo, el algoritmo no debería dejar de ofrecer y explorar en el futuro otros *covers* de piano, porque el hecho de que el usuario no los haya elegido, no significa necesariamente que no le gusten (puesto que el usuario puede realizar una sola elección por vez). Esto hace que el algoritmo siga probando con nuevos ofrecimientos, y aprendiendo a partir de los resultados.

Se debe considerar aquí que, a diferencia de otros algoritmos a los que se les pide obtener el mayor volumen de un único resultado, como ocurre –por ejemplo– en el caso de las campañas publicitarias que buscan maximizar las descargas de una aplicación, los registros en un formulario o las ventas en un sitio de comercio electrónico, en el caso de los sistemas de recomendación se prevé un funcionamiento continuo. En ese sentido, entra en juego la variable *tiempo*: los algoritmos le otorgan un mayor peso a la actividad más próxima del usuario, por ejemplo, qué videos ha visto un usuario o qué música ha escuchado *recientemente*. En forma complementaria, les otorgan un peso menor o nulo a los consumos que están más alejados en el tiempo, que pueden corresponder a obras o tipos de obras en las que el usuario, por alguna razón,



probablemente haya perdido interés. Esto implica una gestión más compleja, en la que el algoritmo no sólo debe aprender y recordar sobre elecciones y preferencias, sino también olvidar (o dejar de recordar).

En relación con este tipo de funcionamientos, en los que las plataformas buscan comprender los gustos o preferencias de los usuarios con el fin de ofrecerles obras que presuntamente sean de su agrado, se ha señalado el riesgo de que construyan “un *loop* del usuario sobre sí: más de lo mismo, más de sí mismo” (CINGOLANI, 2017a, p.42). Dicho en otros términos, se evaluó que estos funcionamientos podían estar restringiendo las posibilidades de aparición de la novedad. Una novedad que, en el sistema de los medios masivos, de emisión y programación centralizada, estaba definida desde el lado de la oferta (VERÓN, 2009; CARLÓN, 2016): para el caso de la música, por ejemplo, bastaba con escuchar las emisoras de radio para conocer nuevas obras o nuevos artistas. Retomaremos la discusión acerca del lugar de la novedad en las plataformas de *streaming* hacia el final de este trabajo, una vez que hayamos revisado algunas de las lógicas semióticas que intervienen en su funcionamiento.

Volviendo al caso que estamos trabajando como ejemplo, decíamos recién que el algoritmo había ubicado la obra “en un entramado de categorías y clasificaciones”. Nos preguntamos ahora: ¿el algoritmo efectivamente tuvo en cuenta estas categorías y clasificaciones del video para generar las recomendaciones? ¿O las ha generado a través de alguna otra vía, y la explicación de la ubicación de la obra en ese entramado es resultado de nuestras lecturas? Esta pregunta no puede responderse únicamente observando la superficie textual, porque –como adelantamos en otro trabajo, “desde la superficie textual que es el resultado de la operación del algoritmo, *no se puede rastrear con certeza el tipo de algoritmo interviniente*: justamente, parte del ‘buen funcionamiento’ de los algoritmos, hoy en una etapa avanzada de su desarrollo, es que no dejan huellas específicas de su funcionamiento” (ZELCER, 2022b). Sin embargo, podemos imaginar al menos tres caminos posibles, que en todos los casos habrán implicado la intervención de algoritmos:

- En primer lugar, podemos pensar que el texto inicial ha sido indexado con ciertas categorías o etiquetas, y que por tanto el sistema nos ofrece más opciones de esas categorías o etiquetas. En este caso, el algoritmo estaría funcionando con una lógica similar a la de nuestra explicación.



- En segundo lugar, podemos pensar que este texto ha sido consumido por usuarios de un determinado perfil; y entonces, el algoritmo nos está ofreciendo otros textos consumidos por usuarios de ese perfil. Aquí estaría interviniendo una lógica de tipo matricial, que podemos imaginar, en forma esquemática, como asociada a un cuadro de doble entrada en el cual se cruzan los ítems (en este caso, los videos) con los usuarios que los han consumido. Aquí estaríamos trabajando en el territorio del presupuesto 5. Según reseñan algunos especialistas, estos métodos eran los más habituales hasta alrededor de 2013-2014.¹⁰

- Finalmente, el tercer camino posible es pensar que este texto suele consumirse con otros; y por tanto, este algoritmo nos propone algunos de esos otros textos. Estamos aquí en el caso de la hipótesis 6, que, como adelantamos, se corresponde con varios algoritmos que trabajan por *deep learning*, como las redes neuronales.

Dentro de las redes neuronales hay, además, varios funcionamientos algorítmicos; como ya dijimos, no podríamos adivinar cuál de ellos intervino observando únicamente la superficie textual. Volvamos ahora a nuestro caso y hagamos aquí un ejercicio comparativo con dos modelos de *deep learning*.

Imaginemos, en primer lugar, que intervinieron algoritmos del tipo *deep collaborative filtering*. Supongamos que, en YouTube, muchos usuarios vieron, cada uno, 20 videos (podrían haber sido más, pero se tomarían 20 como muestra). El algoritmo podría ser entrenado con estos “paquetes” de 20 videos. Luego, el algoritmo tomará nuevos paquetes de 20 videos, pero sólo ingresará como *input* 19 de ellos, y buscará predecir cuál sería el número 20. El mismo algoritmo podría ir así refinando su aprendizaje; como se ve, se trata un proceso con iteraciones. Luego, dados algunos videos, el algoritmo podría realizar predicciones que funcionarían como recomendaciones. Y dado un único video, como vimos aquí, podría recomendar otros que suelen verse con él. Este funcionamiento está basado en el hecho de que hay patrones que comienzan a repetirse, porque hay ciertos gustos que se repiten; gustos que se operativizan como elecciones de textos.

¹⁰ Ver, por ejemplo, la conferencia “Deep learning for recommender systems” de Alexandros Karatzoglou, de diciembre de 2018, disponible en <https://bit.ly/3Xog6o9> [Consulta: 12/1/2023]



Sin embargo, podríamos suponer también que el algoritmo que intervino fue del tipo *session based recommendation with recurrent neural networks*. En este caso, a diferencia del anterior, lo que se modela es una secuencia de datos: ya no hablamos de “paquetes”, sino de datos ordenados. El *input* en este caso son sesiones de navegación de usuarios: se registran recorridos (en nuestro ejemplo, serían secuencias de videos consumidos), y lo que el algoritmo intenta predecir es cuál será el siguiente ítem (en este caso, el siguiente video consumido). Aquí tenemos nuevamente un funcionamiento propio de las redes neuronales, con iteraciones o recurrencias que van construyendo el aprendizaje. Este tipo de algoritmo resulta particularmente interesante porque, en términos de lo que propone Alexandros Karatzoglou, concibe la recomendación más como un problema de *ranking* (y por ello, ordenamiento) que de clasificación.

En cualquiera de estos dos casos, aparecen –como adelantábamos– *correlaciones entre consumos de textos*: un texto suele ser elegido cuando se eligen otros. En un caso, el texto puede elegirse por pertenecer a conjunto o “paquete”; en el otro, por formar parte de secuencias de cierta estabilidad. En cuanto a los usuarios o consumidores, estos algoritmos los tienen de algún modo como intermediarios, pero se desembarazan de ellos: trabajan únicamente con los textos y sus consumos. El efecto que puede generarnos como analistas es que el algoritmo seleccionó los nuevos textos para recomendar sobre la base de categorías y clasificaciones, pero –como vimos– la lógica empleada por la red neuronal puede haber sido diferente. De hecho, resulta significativo que, en el caso de las redes neuronales, las reglas o lógicas puestas en juego son muchas veces opacas incluso para el mismo programador. Por ello, desde un punto de vista analítico podemos caracterizar sus efectos, pero habitualmente no podemos hacer lo mismo con sus funcionamientos profundos.

Las lógicas semióticas

Nos proponemos reflexionar ahora acerca del funcionamiento de los algoritmos desde la semiótica de Peirce, retomando de su obra los pasajes en los que, trabajando la semiótica como una lógica, describió los distintos tipos de razonamiento. Comenzaremos por repasar brevemente los principales tipos de razonamiento que propone este autor, para luego regresar a los sistemas de recomendación.¹¹

¹¹ Retomamos en este apartado algunas de las reflexiones que adelantamos en Zelcer, 2022a.



La inducción, la deducción y la abducción son tres tipos de razonamiento que Peirce presenta en su obra en múltiples lugares. Cuando desarrolla sus tres tricotomías del signo, aparecen en la tercera de ellas, que es la que se ocupa de la relación del signo con su interpretante (*rema*, *dicente* y *argumento*) (PEIRCE, 1986, p. 31). Estos tres tipos de razonamiento son presentados como otros tantos tipos de argumento, que se pueden pensar como tres tipos de lógica. Más allá de las explicaciones que incluye en su tercera tricotomía, estos tres modos de razonar aparecen en muchos otros pasajes de su obra, en los que los desarrolla y explica comparativamente.

La *deducción* trabaja con leyes o reglas que se consideran universales; de cualquier caso particular que corresponda a los propuestos por aquella ley se podrá llegar a una conclusión, que será una aplicación particular de esa regla general. Se trata del razonamiento que se corresponde con los silogismos lógicos, compuestos por una premisa mayor, una menor y una conclusión, como en el conocido ejemplo que dice “Todos los hombres son mortales” (premisas mayor), “Sócrates es hombre” (premisas menor) y “Sócrates es mortal” (conclusión). Peirce enfatiza que se trata de un tipo de razonamiento, es decir, de un modo de pensamiento, que no tiene que ver necesariamente con la realidad o el mundo exterior. Por ende, y complementariamente, la conclusión será válida independientemente de ese mundo exterior:

Nuestra inferencia es válida si y sólo si hay realmente una relación tal entre el estado de cosas supuesto en las premisas y el estado de cosas afirmado en la conclusión. Si realmente es así o no, es una cuestión de la realidad y no tiene nada que ver en absoluto con cómo estemos inclinados a pensar. (Peirce, 2012b, p. 278)

Suele decirse que la *inducción*, en cambio, reúne varios casos particulares que, a medida que presentan algún tipo de regularidad, pueden dar lugar a la formulación de una regla general. Por ello, es corriente escuchar que la deducción trabaja de lo general a lo particular, mientras que la inducción va de lo particular a lo particular, en busca de lo general. Sin embargo, Peirce enfatiza que, en rigor, la inducción parte ya de una teoría, que se pone a prueba; es decir, trabaja con casos particulares, pero ya con algún tipo de suposición que busca probar: “La inducción consiste en partir de una teoría, deducir de ella predicciones de fenómenos, y observar esos fenómenos para ver *qué tan cercanamente* concuerdan con la teoría” (Peirce, 2012b, p. 282).

En el pensamiento de Peirce, la *abducción* aparece como el tercer modo de razonamiento. Se trata de la adivinación, de la conjetura, de la intuición, de la



elaboración de hipótesis (pero no de su comprobación). Cualquier conocimiento nuevo, dice Peirce, depende de la formación de una hipótesis, un proceso que es del orden de la abducción:

La abducción es el proceso de formar una hipótesis explicativa. Es la única operación lógica que introduce alguna idea nueva, pues la inducción no hace más que determinar un valor y la deducción meramente desenvuelve las condiciones necesarias para una hipótesis pura.

La Deducción demuestra que algo debe ser, la Inducción muestra que algo es realmente operativo y la Abducción sugiere que algo puede ser. (Peirce, 2012b, p.283).

Peirce explica ciertos mecanismos que operan en la elaboración de las hipótesis, que él entiende como un tipo de inferencias sintéticas. Nos interesa recuperarlos aquí, porque señalan un camino que permite conceptualizar algunos funcionamientos del *machine learning*. Dice Peirce:

La hipótesis se da donde encontramos alguna circunstancia muy curiosa, que se explicaría al suponer que era un caso de una cierta regla general, y en consecuencia adoptamos esa suposición, o donde encontramos que dos objetos se parecen mucho entre sí en ciertos aspectos e inferimos que se parecen mucho entre sí en otros aspectos. (Peirce, 2012a, p. 236).

Peirce propone aquí que hay una suerte de “señales reveladoras”: las leemos, a veces incluso de forma no del todo consciente. Se trata de lectura de *indicios*: eso que Peirce llamaba “instinto” se apoya, en verdad, en la percepción (tal vez inconsciente) de *conexiones entre aspectos del mundo*. Estas conexiones se encuentran a partir de la identificación de *semejanzas*; por ello, Peirce insiste, cuando explica el funcionamiento de las hipótesis, en la cuestión de los aspectos en los que los objetos *se parecen*. La abducción sería entonces en estos casos *la capacidad de elaborar ciertas hipótesis a partir del hallazgo de semejanzas*. Como se sabe, los indicios no son, por lo general, signos seguros. Dicho de otra manera, esa conexión efectivamente observada, podría ser acertada o equivocada como explicación de la vinculación entre esos “otros aspectos” del mundo. Por ello, Peirce afirma que, si bien todo conocimiento nuevo proviene de conjeturas, estas son inútiles si no se prueban en la investigación: las hipótesis deben ser sometidas a la prueba de la inducción.

Volvamos ahora a los sistemas de recomendación. Se puede pensar que, cuando comienzan a operar, estos algoritmos funcionan predominantemente con lógicas abductivas: inicialmente exponen al usuario distintas opciones de obras, a partir de



algún primer consumo o indicio. Cuando el usuario sigue realizando elecciones (sea aceptando recomendaciones, o accediendo a los textos por otras vías, como ser las búsquedas), el algoritmo comienza a hacer hipótesis acerca de cuáles podrían ser las *semejanzas pertinentes* entre las distintas elecciones; lo vimos a propósito del ejemplo del video de Sangah Noona en YouTube. La capacidad de encontrar estos parecidos, que Peirce identificaba, entre fines del siglo XIX y comienzos del XX, como una facultad humana, hoy se encuentra también en sistemas informáticos. En estos casos, desde luego, no se explica ya por una supuesta intuición o iluminación, como decía Peirce a propósito de los humanos, sino por la combinación de un volumen masivo de datos acerca de los usuarios y sus comportamientos almacenados en forma digital y la capacidad y velocidad de procesamiento que tienen los actuales equipos informáticos. A partir del hallazgo de semejanzas, se puede pensar que el sistema elabora una conjetura o abducción que da lugar a una hipótesis, a partir de la cual elabora una recomendación, que se pone a prueba. Como señalaba Peirce, el hallazgo de ciertas semejanzas da lugar a la pregunta acerca de si habrá semejanzas en otros aspectos. En el caso de las plataformas: si varios usuarios a los que les gusta A, también les gusta B, es probable que a otros usuarios que consumen A, también les guste B, hipótesis que también deberá poner a prueba; este es un camino posible para la construcción de perfiles de usuarios (hipótesis 5). La puesta a prueba se lleva a cabo en la misma recomendación: se ofrecen las sugerencias, y el algoritmo observa *qué tan cercanamente* concuerdan las respuestas de los usuarios con esa hipótesis: se trata de un funcionamiento inductivo. Peirce conceptualiza este tipo de puesta a prueba de la hipótesis como una “investigación experimental”, que en este caso sería llevada a cabo por el propio algoritmo. Explica Peirce:

Cuando digo que por razonamiento inductivo entiendo un curso de investigación experimental, no entiendo experimento en el sentido estrecho de una operación por la que uno varía las condiciones de un fenómeno casi como uno quiera (...) Un experimento, dice Stöckhardt en su excelente *School of Chemistry*, es una pregunta que se le hace a la naturaleza. Como cualquier interrogatorio, se basa en una suposición. Si esa suposición es correcta, puede esperarse cierto resultado razonable bajo ciertas circunstancias que pueden crearse, o en todo caso, encontrarse. La pregunta es: ¿será ése el resultado? Si la Naturaleza responde “¡No!”, el experimentador ha conseguido una pieza importante de conocimiento. Si la Naturaleza dice “Sí”, las ideas del experimentador permanecen tal y como eran, sólo que un poco más sedimentadas. (PEIRCE, 2012, p. 281)



En este caso, al ser el propio algoritmo el que realiza la investigación experimental de la que habla Peirce, es también el algoritmo el que recibe, como respuesta, los “sí” o “no”, no de la naturaleza, sino de los usuarios, según cliquen o no cada una de las recomendaciones. Se trata, en estos casos, de hipótesis que trabajan siempre con grados de probabilidad, buscando una maximización que nunca llega a comportarse del modo en que lo hacen las leyes con las que se maneja la lógica deductiva: no hay premisas mayores siempre verdaderas, sino maximización de probabilidades. Dicho de otra manera: un usuario nunca cliqueará todas las recomendaciones (cosa que, además, sería imposible, puesto que en prácticamente todas las plataformas se suele ofrecer más de una recomendación por vez), pero seguramente vaya cliqueando, progresivamente, varias de ellas. El sistema irá acumulando y precisando el conocimiento acerca de los gustos de ese usuario a lo largo del tiempo. Cuanto más conoce el sistema a un usuario, es probable que más predomine un funcionamiento tendiente a lo deductivo, en el que se propongan obras específicas de preferencias relativamente verificadas empíricamente. No obstante, como vimos, los algoritmos están programados para darles mayor peso a los consumos recientes, por lo que los *inputs* se renuevan permanentemente, y el funcionamiento abductivo no se abandona. Si, por múltiples razones, el usuario consume otro tipo de contenidos (porque los ha propuesto otro algoritmo basado en contenidos, porque lo ha buscado, porque ha llegado a partir de un enlace recomendado por otro usuario, etc.), el algoritmo volverá a experimentar inductivamente hipótesis sobre sus nuevos gustos.

Los algoritmos que hemos identificado como de aprendizaje profundo, que se entrenan para encontrar cuál es el elemento que complementa una serie o un conjunto, parten también de lógicas abductivas, pero su funcionamiento inductivo parece perseguir la llegada a una regla de tipo deductivo (que luego será aplicable o no a cada usuario según el perfil o comportamiento que presente). Esto deja en evidencia que, en el movimiento que ya identificamos de “desembarazarse” de los usuarios, y trabajar con las relaciones entre los textos, estos algoritmos *ganan autonomía en relación con los posibles cambios de gustos o preferencias de las personas que emplean el sistema*. Ubicada en el nivel de los terceros peircianos, la lógica de tipo deductivo da cuenta de algún “hábito o ley” (PEIRCE, 1986): el algoritmo podría identificar y reconstruir ese hábito a partir de usuarios que lo pongan en práctica, y luego, podría hacerlo operar en



sus recomendaciones, aun cuando esos usuarios específicos con los que lo aprendió ya no lo pongan en práctica. Lo vemos con un ejemplo: un usuario adulto que emplea una plataforma para poner videos a su hijo pequeño podría contribuir, con muchos otros usuarios, al aprendizaje de un algoritmo sobre videos adecuados para niños. Luego, el hijo de ese usuario puede crecer, y por tanto, sus preferencias variar; sin embargo, el algoritmo habrá aprendido acerca de estos tipos de videos, y podrá recomendárselos a otros usuarios.

El lugar de la novedad

En la revisión que hicimos acerca del funcionamiento de los algoritmos de aprendizaje automatizado encontramos que hay un lugar relevante para la identificación de las *semejanzas*, un proceso que ligamos a la combinación de funcionamientos abductivos con inductivos. De hecho, una buena parte de la operación de estos sistemas consiste en buscar otros textos que guarden semejanza con los ya consumidos, basados sobre los dos presupuestos que ya explicitamos, y sobre la hipótesis número 3: si se encuentran otros textos que compartan rasgos o categorías con los ya consumidos, muy probablemente serán del gusto del usuario. Ahora bien: si tales lógicas dominan las recomendaciones, ¿dónde queda el espacio para la novedad?

Señalemos, en principio, que la pregunta parece encerrar algo de capcioso: cuando los algoritmos aprenden sobre nuestros gustos, nos hacen recomendaciones para que conozcamos otras obras. Pero entonces, les objetamos que nos traen “más de lo mismo”. Sin embargo, la revisión que acabamos de realizar nos muestra, al menos, dos modos en los que los algoritmos de aprendizaje automático pueden traer cierta novedad.

Por un lado, deberíamos relativizar la idea de que estos algoritmos traen siempre “más de lo mismo”. El sistema de indexación que combina categorías con etiquetas, a lo que puede sumarse información adicional que los algoritmos pueden extraer de los propios contenidos,¹² hace que, en términos de las clasificaciones sociales con las que la cultura suele organizar los textos –géneros, estilos (de autor, de época, artísticos), lenguajes, etc.– los criterios sean muy numerosos y variados. De esto puede resultar, por ejemplo, que podemos estar viendo un video de una orquesta ejecutando

¹² Nos estamos refiriendo a la funcionalidad que se conoce en inglés como “extracting features from content”. Al respecto, puede consultarse en el referido video de Alexandros Karatzoglou.



una obra de Bach, y desde allí desplazarnos a una obra de Falvetti, que comparte con la primera la etiqueta de “barroco”. Y Falvetti definitivamente no es “lo mismo” que Bach. Otra etiqueta en la obra inicial podría ser “brillant classics”;¹³ esta etiqueta podríamos llevarnos a obras para piano de Mozart, que tampoco es “lo mismo” que Bach. Y desde allí, podríamos avanzar por etiquetas como “piano” y pasar a una obra inscripta en otro estilo de música más contemporáneo, también ejecutada en ese instrumento. Incluso cuando un sistema nos ofrece una obra musical del mismo compositor, o una película del mismo director, pecaríamos de apocalípticos si pusiéramos todo el foco en los aspectos repetitivos, y no reconociéramos que, finalmente, estamos ante un mecanismo que nos permite conocer nuevas producciones culturales, probablemente desconocidas hasta entonces por nosotros, y presumiblemente de nuestro interés.

Por el otro, las lógicas que involucran a otros usuarios –tanto las que lo hacen en forma directa, como aquellas que trabajan sobre las afinidades y correlaciones entre textos (es decir, las basadas sobre las hipótesis 5 y 6) – que, como vimos, en la actualidad tienden a ser trabajadas cada vez más mediante redes neuronales y *deep learning*, pueden realizar recomendaciones ya no necesariamente basadas en las semejanzas, sino precisamente en correlaciones, que dan cuenta de hábitos: textos que suelen consumirse con otros textos. Este es claramente otro espacio de aparición de la novedad.

Como se ve, se trata en todos los casos de *juegos de desplazamientos*: por categorías, por etiquetas, por correlación en los consumos de terceros. Dicho de otro modo, hay cierta lógica de la contigüidad, ya sea por alguna categoría o etiqueta en común o por afinidades (en los perfiles, en los conjuntos o en las series de consumos). Al día de hoy, sobre estos distintos algoritmos, ya se están montando nuevos algoritmos de aprendizaje automatizado, que observan y aprenden cuál o cuáles de estos criterios resultan más relevante para cada quien, y eligen así qué algoritmo emplear según el usuario del que se trate; y otros que atienden a cuestiones contextuales, como el momento del día, o el dispositivo que se está empleando; es decir que se van sumando mecanismos que buscan al mismo tiempo diversificar y precisar la oferta. A fin de cuentas, como advertía Thompson (2008) hace ya varios años “las

¹³ Esta etiqueta aparece a veces en YouTube, por el uso coloquial que se le da al término “clásico” para abarcar diversos estilos artísticos musicales, que incluyen, en este caso, también el barroco.



máquinas podrían estar entendiendo algo acerca de nosotros que nosotros mismos desconocemos”.¹⁴

Llegado este punto, nos parece que la creencia de que no aparecen novedades reposa en una confusión: la suposición de que cada texto está clasificado en una única categoría, y que los algoritmos sólo pueden ofrecernos más textos de esa categoría. Como observamos, los sistemas de indexación son mucho más ricos y complejos: cada uno de ellos puede tener múltiples etiquetas, y así formar parte de múltiples clasificaciones que, como se ve, no presentan necesariamente sistematicidad. Así, las sugerencias que un sistema de recomendación puede dar a partir de un mismo texto pueden ser muy numerosas, en la medida en que pueden seguir criterios muy variados. Y en muchos casos, como también vimos, las recomendaciones parten de la identificación de correlaciones estables que dan cuenta de hábitos en el consumo de los textos que generan agrupamientos de obras; es decir, no siempre hay un criterio basado en clasificaciones, categorías o etiquetas.

Si consideramos que, junto a las sugerencias realizadas por los algoritmos (tanto los que funcionan por aprendizaje automático como aquellos que no lo hacen), se encuentran también distintos contenidos seleccionados editorialmente, las plataformas de *streaming* terminan por inscribirse en lo que José Luis Fernández llama un momento de *postbroadcasting*, en el que se registran fenómenos en los que conviven lógicas del *broadcasting* con la del *networking* (FERNÁNDEZ, 2022). No se trata ya de *broadcasting* al modo en que se observó en el momento de hegemonía de los medios masivos: YouTube, Spotify o Netflix no organizan ni programan la vida social (Carlón, 2016); sin embargo, presentan algunos espacios en los cuales los contenidos están definidos por la plataforma, que se comporta aquí como institución emisora. La sobreoferta propia de este momento de la mediatización, sin embargo, hace que ninguna de estas plataformas tenga el poder que presentaban hasta fines del siglo XX los medios masivos. Junto a estas lógicas, los distintos algoritmos que tienen en cuenta consumos anteriores generan recomendaciones basadas en funcionamientos más propios del *networking*, y retoman para las recomendaciones la historia de los consumos de otros usuarios, así como también la del propio usuario.

¹⁴ Citado en Hallinan y Striphas, 2016 (ver <https://bit.ly/3XopuIx>). El texto referido puede verse en <https://nyti.ms/3Zs8dA3>. Consulta: 12 ene. 2023.



Referencias

CARLÓN, Mario. **Después del fin**. Una perspectiva no antropocéntrica sobre la post-tv, el post-cine y youtube. Buenos Aires: La Crujía, 2016.

CINGOLANI, Gastón. “Sistemas de recomendación, mediatizaciones de lo preferible y enunciación”, en Busso, Mariana Patricia y Camuso, Mariángeles (eds.) **Mediatizaciones en tensión: el atravesamiento de lo público**. Rosario: UNR Editora, 2017. Páginas 30 a 47.

CINGOLANI, Gastón. “Estrategias para el acceso: los sitios de recomendación como espacios de tensiones en la circulación y mediatización del reconocimiento”, en Paulo César Castro (org.) **A circulação discursiva: entre produção e reconhecimento**. Maceió: EDUFAL, 2017. Páginas 125-140. ISBN 978-85-5913-125-3

FERNÁNDEZ, José Luis. **Plataformas mediáticas**. Elementos de análisis y diseño de nuevas experiencias. Buenos Aires: La Crujía, 2018

FERNÁNDEZ, José Luis. **Vidas mediáticas**. Entre lo masivo y lo individual. Buenos Aires: La Crujía, 2022.

PEIRCE, Charles Sanders. **La ciencia de la semiótica**. Buenos Aires: Nueva Visión, 1986.

PEIRCE, Charles Sanders. **Obra filosófica reunida**. Tomo I (1867-1893). México D.F.: Fondo de Cultura Económica, 2012. Traducción de Darin McNabb.

PEIRCE, Charles Sanders. **Obra filosófica reunida**. Tomo II (1893-1913). México D.F.: Fondo de Cultura Económica, 2012. Traducción de Darin McNabb.

STEIMBERG, Oscar. **Semiótica de los medios masivos**. Atuel: Buenos Aires, 1993.

UMAN, Ignacio. El efecto Netflix: cómo los sistemas de recomendación transforman las prácticas de consumo cultural y la industria de contenidos. **Cuadernos de Comunicólogos**, año 6, número 6, 2018. Páginas 27 a 42. Disponible en <https://bit.ly/3GVQIAK>. Consulta: 29 mai. 2022.

VERÓN, Eliseo. **La semiosis social. Fragmentos** de una teoría de la discursividad. Barcelona: Gedisa, 1996. Edición original: 1987.

VERÓN, Eliseo El fin de la historia de un mueble. En: CARLÓN, Mario; SCOLARI, Carlos A. (editores). **El fin de los medios masivos**. Buenos Aires: La Crujía, 2009. Páginas 229-248.

ZELCER, Mariano. Machine learning y lógicas semióticas: el caso de la publicidad digital. En: **Revista La Trama de la Comunicación**, volumen 26, número 2 (en prensa), 2022. ISSN: 2314-2634 (en línea y 1668-5628 (impresa). URL: <https://bit.ly/3GsAIEQ>. Consulta: 27 mai. 2022.

ZELCER, Mariano. Algoritmos de *machine learning* en plataformas de contenidos: una aproximación semiótica. En: **Revista Chilena de Semiótica**, número 17, 2022. ISSN 0717-3075. URL: <https://bit.ly/3QA45K1>. Consulta: 2 jul. 2022.





Este é um ARTIGO publicado em acesso aberto (*Open Access*) sob a licença *Creative Commons Attribution*, que permite uso, distribuição e reprodução em qualquer meio, sem restrições, desde que o trabalho original seja corretamente citado.